

Hrsg.: Frank Straube, Helmut Baumgarten

Manuel Weinke

Machine Learning im Logistikmanagement – Entwicklung eines Gestaltungsansatzes zum Einsatz von ML-Anwendungen in logistischen Entscheidungsprozessen

Manuel Weinke

**Machine Learning im Logistikmanagement –
Entwicklung eines Gestaltungsansatzes zum Einsatz von
ML-Anwendungen in logistischen Entscheidungsprozessen**

Die *Schriftenreihe Logistik der Technischen Universität Berlin* wird herausgegeben von:
Prof. Dr.-Ing. Frank Straube,
Prof. Dr.-Ing. Dr. rer. pol. h.c. Helmut Baumgarten

Manuel Weinke

**Machine Learning im Logistikmanagement –
Entwicklung eines Gestaltungsansatzes zum Einsatz von
ML-Anwendungen in logistischen Entscheidungsprozessen**

Bibliografische Information der Deutschen Nationalbibliothek

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über <http://dnb.dnb.de> abrufbar.

Universitätsverlag der TU Berlin, 2023

<https://verlag.tu-berlin.de>

Fasanenstr. 88, 10623 Berlin

Tel.: +49 (0)30 314 76131

E-Mail: publikationen@ub.tu-berlin.de

Zugl.: Berlin, Techn. Univ., Diss., 2022

Gutachter: Prof. Dr.-Ing. Frank Straube

Gutachter: Prof. Dr. André Ludwig (Kühne Logistics University)

Die Arbeit wurde am 24. November 2022 an der Fakultät VII unter Vorsitz von Prof. Dr. Timm Teubner erfolgreich verteidigt.

Diese Veröffentlichung – ausgenommen anderweitig gekennzeichnete Inhalte – ist unter der CC-Lizenz CC BY 4.0 lizenziert.

<http://creativecommons.org/licenses/by/4.0/>

Druck: docupoint GmbH

Satz/Layout: Manuel Weinke

ORCID iD Manuel Weinke: 0000-0001-8387-4333

<https://orcid.org/0000-0001-8387-4333>

ISBN 978-3-7983-3297-3 (print)

ISBN 978-3-7983-3298-0 (online)

ISSN 1865-3170 (print)

ISSN 2197-0564 (online)

Zugleich online veröffentlicht auf dem institutionellen Repositorium der Technischen Universität Berlin:

DOI 10.14279/depositonce-16658

<http://dx.doi.org/10.14279/depositonce-16658>

Für meine Familie

Inhaltsübersicht

Inhaltsübersicht	II
Inhaltsverzeichnis	III
Abbildungsverzeichnis	VIII
Tabellenverzeichnis	XI
Abkürzungsverzeichnis	XII
1 Einleitung	1
2 Theoretische Grundlagen	14
3 Forschungsmethodik	78
4 Status Quo und Entwicklungen	93
5 Anwendungsmöglichkeiten	132
6 Anforderungen	174
7 Gestaltungsansatz	214
8 Fazit	298
Anhang	309
Literaturverzeichnis	315

Inhaltsverzeichnis

Inhaltsübersicht	II
Inhaltsverzeichnis	III
Abbildungsverzeichnis	VIII
Tabellenverzeichnis	XI
Abkürzungsverzeichnis	XII
1 Einleitung	1
1.1 Ausgangssituation und Motivation	1
1.2 Zielsetzung und Untersuchungsfeld der Arbeit	6
1.3 Forschungsdesign	9
1.3.1 Wissenschaftstheoretische Einordnung	9
1.3.2 Forschungskonzeption	10
1.4 Aufbau der Arbeit	12
2 Theoretische Grundlagen	14
2.1 Forschungsleitende Theorien	15
2.1.1 Technologische Grundbegriffe	15
2.1.2 Strategische Bedeutung von Technologien	17
2.1.2.1 Market-based View	18
2.1.2.2 Resource-based View	19
2.1.2.3 Competence-based View	19
2.1.2.4 Dynamic Capabilities View	20
2.1.3 Adoption von Technologien	21
2.1.3.1 Diffusion of Innovations	22
2.1.3.2 Technology-Organization-Environment	24
2.1.3.3 Mensch-Technik-Organisation	25
2.1.3.4 Technology-to-Performance Chain	26
2.1.4 Implikationen für die Untersuchung	28
2.2 Logistikmanagement	29
2.2.1 Logistik und Logistiksysteme	29
2.2.2 Logistikprozesse	31
2.3 Entscheidungsprozesse und -techniken	32
2.3.1 Entscheidungstheoretische Grundbegriffe	33
2.3.2 Aktivitäten in Entscheidungsprozessen	33
2.3.3 Merkmale von Problemen	35
2.3.4 Manuelle Ausführung von Entscheidungen	39
2.3.5 Technische Unterstützung von Entscheidungen	40
2.3.5.1 Systematisierung	40

2.3.5.2	Modellgestützte Entscheidungstechniken.....	41
2.3.5.3	Abgrenzung zu datengestützten Entscheidungstechniken.....	44
2.4	Machine Learning und Künstliche Intelligenz	45
2.4.1	Künstliche Intelligenz.....	45
2.4.1.1	Modellierung menschlicher Intelligenz.....	46
2.4.1.2	Wissenschaftstheoretische Einordnung und Definition von KI	47
2.4.1.3	Fähigkeiten und Teilbereiche von KI	49
2.4.1.4	KI-Hypothesen (schwache und starke KI)	51
2.4.2	Lernende Systeme.....	53
2.4.2.1	Grundlagen einer systemseitigen Lernfähigkeit	54
2.4.2.2	Expertensysteme (symbolische KI)	56
2.4.2.3	Machine Learning (subsymbolische KI).....	57
2.4.2.4	Vergleich beider KI-Paradigmen und Ableitung eines Lernbegriffes	59
2.4.3	Systematisierung von Machine Learning.....	63
2.4.3.1	Lerntypen	64
2.4.3.2	Lernverfahren	69
2.4.3.3	Lernaufgaben	72
2.5	Synthese: ML-Anwendungen im Logistikmanagement.....	75
3	Forschungsmethodik	78
3.1	Typenbildung.....	78
3.1.1	Systematische Literaturanalyse.....	80
3.1.2	Clusteranalyse.....	82
3.2	Empirische Untersuchung.....	84
3.2.1	Gruppendiskussion.....	86
3.2.2	Onlinebefragung	87
3.2.3	Experteninterviews	90
4	Status Quo und Entwicklungen.....	93
4.1	Forschungsstand.....	93
4.1.1	Entwicklungsprozess	96
4.1.2	Anwendungsmöglichkeiten	99
4.1.3	Betrieblicher Einsatz	102
4.2	Praxisstand	104
4.3	Fallstudien zu Anwendungsfällen aus der Praxis	109
4.3.1	Anwendungsfall 1: Ermittlung des mittelfristigen Materialbedarfes.....	110
4.3.2	Anwendungsfall 2: Ermittlung der zukünftigen Produktqualität	113
4.3.3	Anwendungsfall 3: Multi-Echelon-Bestandsoptimierung	116
4.3.4	Anwendungsfall 4: Detektion von Risiken in globalen Lieferketten	118
4.3.5	Zusammenfassung der Fallstudien	121
4.4	Zukünftige Entwicklungen	123
4.4.1	Forschungstrends zu ML	123

4.4.2	Umfeldentwicklungen.....	128
5	Anwendungsmöglichkeiten	132
5.1	Forschungsdesign.....	132
5.2	Charakterisierung der Anwendungstypen.....	136
5.2.1	Problemlösungsfähigkeiten	136
5.2.1.1	Identifikation.....	138
5.2.1.2	Analyse und Bewertung.....	139
5.2.1.3	Prognose.....	140
5.2.1.4	Optimierung	142
5.2.2	Logistische Entscheidungsprozesse	143
5.2.2.1	Langfristige Beschaffungs- und Absatzplanung	145
5.2.2.2	Bedarfs- und Kapazitätsmanagement	146
5.2.2.3	Lieferantenmanagement.....	147
5.2.2.4	Produktionsplanung und -steuerung.....	148
5.2.2.5	Transportmanagement.....	149
5.2.2.6	Prozessmonitoring	150
5.2.2.7	Supply Chain Risk und Performance Management.....	151
5.3	Bewertung und Interpretation des Anwendungsspektrums	152
5.3.1	Abdeckung der Referenzstrukturen für Entscheidungsprozesse	153
5.3.2	Umsetzungsstand und Zusammenhänge zwischen den Typen.....	156
5.3.3	Zukünftige Erweiterungsmöglichkeiten.....	159
5.3.4	Bedeutung für die Praxis	160
5.4	Auswirkungen auf logistische Entscheidungsprozesse	163
5.4.1	Wirkungsdimensionen	163
5.4.1.1	Transparenzerhöhung.....	164
5.4.1.2	Faktenbasierte Entscheidungen	165
5.4.1.3	Antizipative Planung	165
5.4.1.4	Autonome Entscheidungen.....	166
5.4.1.5	Dynamische Entscheidungen	167
5.4.1.6	Ganzheitliche Planung	167
5.4.2	Nutzenpotenziale	168
5.4.3	Risiken	170
5.5	Synthese: Eignung von Anwendungsfällen.....	171
6	Anforderungen	174
6.1	Forschungsdesign und Taxonomie der Anforderungen.....	174
6.2	Funktionen	176
6.2.1	Lernfähigkeit	177
6.2.2	Entscheidungsfähigkeit.....	177
6.2.3	Autonomie.....	178
6.2.4	Auswirkungsermittlung und Szenarienbildung	182

6.3	Qualitätseigenschaften.....	182
6.3.1	Zuverlässigkeit.....	183
6.3.2	Nachvollziehbarkeit.....	184
6.3.3	Kontrollierbarkeit der Entscheidungsausführung.....	185
6.3.4	Kontrollier- und Rückverfolgbarkeit des Lernprozesses.....	185
6.3.5	Manipulationssicherheit.....	186
6.3.6	Verfügbarkeit.....	187
6.3.7	Business Case.....	187
6.3.8	Skalierbarkeit.....	188
6.3.9	Strategic Fit.....	189
6.3.10	Compliance.....	189
6.4	Umfeldeigenschaften.....	190
6.4.1	Datenverfügbarkeit.....	191
6.4.2	Datenqualität.....	192
6.4.3	IT-Vernetzung.....	193
6.4.4	IT-Performance.....	193
6.4.5	Strategische Vorgaben.....	194
6.4.6	Standardprozesse.....	194
6.4.7	Komplexitätsbeherrschung.....	196
6.4.8	Akzeptanz.....	197
6.4.9	Transparenz.....	198
6.4.10	Interdisziplinäre Kooperation.....	199
6.4.11	Systemdenken.....	200
6.4.12	Personal und Finanzen.....	201
6.4.13	Kompetenz.....	201
6.4.14	Governance.....	202
6.5	Bewertung.....	203
6.5.1	Funktionen.....	203
6.5.2	Qualitätseigenschaften.....	204
6.5.3	Umfeldeigenschaften.....	207
6.5.4	Priorisierung.....	212
7	Gestaltungsansatz.....	214
7.1	Forschungsdesign und Übersicht.....	214
7.1.1	Entwicklung.....	214
7.1.2	Validierung.....	217
7.2	Strategie: Langfristig ausgerichteter Einsatz von ML.....	218
7.2.1	Technologieoffene Vision und menschenzentriertes Leitbild.....	219
7.2.2	Anwendungsfälle als Synthese von ML-Potenzialen und betrieblichen Problemen.....	221
7.2.3	Strategieorientierte Bewertung und Harmonisierung von Anwendungsfällen.....	222
7.2.4	Validierung.....	223

7.3	Ablauforganisation: Standardprozess zur Auswahl und Umsetzung von ML-Anwendungen..	225
7.3.1	Struktur des Vorgehensmodells	226
7.3.2	Problemanalyse und Sollkonzeption	230
7.3.3	Vorbereitung der Datenbasis	240
7.3.4	Modellentwicklung	247
7.3.5	Betriebliche Einführung.....	251
7.3.6	Validierung.....	255
7.4	Aufbauorganisation: Agile Strukturen für ML-Projekte mit zentraler Koordination	265
7.4.1	Bildung interdisziplinärer ML-Projektteams	266
7.4.2	Skalierung agiler Prinzipien im IT-Bereich.....	268
7.4.3	Zentrale Koordination mittels Digital Transformation Office	270
7.4.4	Validierung.....	271
7.5	Mensch-Computer-Interaktion: Einsatz kollaborierender Systeme	273
7.5.1	Stärkung menschlicher Fähigkeiten mittels Shared Autonomy.....	274
7.5.2	Erweiterung des menschlichen Aufgabenspektrums	276
7.5.3	Integrierte Qualitätskontrolle.....	278
7.5.4	Validierung.....	279
7.6	Kompetenzmanagement: Mitarbeiter für Einsatz von ML sensibilisiert und befähigt	281
7.6.1	Qualifizierung von Fachkräften ergänzt um externes Wissen	282
7.6.2	Grundverständnis zu ML bei allen Organisationsmitgliedern	284
7.6.3	Nutzerseitige Interpretation des Systemverhaltens	287
7.6.4	Validierung.....	288
7.7	Datenmanagement: Skalierbare ML-Services auf Basis konsolidierter Daten	289
7.7.1	Systemagnostische Datenintegration mittels Data Lakes	290
7.7.2	Digital Twins für kontextbezogene Datenaufbereitung	291
7.7.3	Modulare Plattform als Host und Inkubator für ML-Anwendungen	292
7.7.4	Validierung.....	294
7.8	Zusammenfassung der Ergebnisprüfung	296
8	Fazit.....	298
8.1	Zusammenfassung.....	298
8.2	Kritische Würdigung	303
8.3	Ausblick.....	306
	Anhang	309
	Literaturverzeichnis	315

Abbildungsverzeichnis

Abbildung 1: Entwicklungsstufen der digitalen Transformation der Logistik	4
Abbildung 2: Voraussetzungen in Unternehmen für den Einsatz von ML in der Logistik	5
Abbildung 3: Prozessuale und technische Dimension des Untersuchungsfelds	8
Abbildung 4: Aufbau und Forschungsprozess der Arbeit	13
Abbildung 5: Systemorientiertes Begriffsverständnis von Technologien	16
Abbildung 6: Systemtechnisches Modell vom Informationssystemen	17
Abbildung 7: Theorien zur Erklärung der strategischen Bedeutung von Technologien	18
Abbildung 8: Theorien zur Gestaltung der Adoption von Technologien	22
Abbildung 9: Adoptionsprozess	23
Abbildung 10: TOE-Modell	24
Abbildung 11: TPC-Modell	27
Abbildung 12: Systematisierung von Prozessen im Logistikmanagement	32
Abbildung 13: Phasen von Entscheidungsprozessen	34
Abbildung 14: Systematisierung von Methoden für Entscheidungstechniken	41
Abbildung 15: Prinzip von modellgestützten Entscheidungstechniken	42
Abbildung 16: Abgrenzung von ML, Analytics und OR	45
Abbildung 17: Menschliche Kognition als Informationsverarbeitungssystem	47
Abbildung 18: Einordnung von KI in Wissenschaftsdisziplinen	48
Abbildung 19: Funktionsprinzip von ML-Anwendungen	58
Abbildung 20: Schematischer Vergleich von Expertensystemen und ML-Anwendungen	62
Abbildung 21: Systematisierung von ML	64
Abbildung 22: Aufbau eines tiefen neuronalen Netzes (Deep Learning)	68
Abbildung 23: Zielkonflikt der Genauigkeit und Interpretierbarkeit von Lernverfahren	71
Abbildung 24: Begriffsabgrenzung von ML und ML-Anwendungen	75
Abbildung 25: Systemtechnisches Modell von ML-Anwendungen im Logistikmanagement	77
Abbildung 26: Methoden der Typenbildung	80
Abbildung 27: Vorgehen bei der systematischen Literaturanalyse	80
Abbildung 28: Vorgehen und Ergebnisse der Identifikation von ML-Anwendungen	82
Abbildung 29: Vorgehen bei der Clusteranalyse	83
Abbildung 30: Mixed-Method-Design der empirischen Untersuchung	85
Abbildung 31: Vorgehen bei der Gruppendiskussion	86
Abbildung 32: Vorgehen bei der Onlinebefragung	88
Abbildung 33: Charakterisierung der Datenbasis der Onlinebefragung	90
Abbildung 34: Vorgehen bei den problemzentrierten Interviews	90
Abbildung 35: Phasen des CRISP-DM	97
Abbildung 36: Entwicklungsprozess von ML-Modellen	98

Abbildung 37: Anwendungsspektrum von ML in der Logistik	105
Abbildung 38: Veränderungspotenzial von ML für die Logistik	105
Abbildung 39: Strategische Bedeutung von ML in der Logistik	105
Abbildung 40: Bedeutung von ML für logistische Aufgabenarten	106
Abbildung 41: Phasen des Umsetzungsstands von ML	106
Abbildung 42: Umsetzungsstand von ML in Unternehmensbereichen	107
Abbildung 43: Umsetzungsstand von ML für logistische Aufgabenarten	108
Abbildung 44: Wissensstand zum Einsatz von ML in der Logistik	109
Abbildung 45: Untersuchungsdimensionen zu Anwendungsmöglichkeiten von ML	133
Abbildung 46: Bildung von Typen für Probleme und Problemlösungsfähigkeit von ML	134
Abbildung 47: Korrelationsmatrizen für beide Merkmalsarten	135
Abbildung 48: Dunn-Indizes für die Clusteranzahl beider Subsysteme	135
Abbildung 49: Dendrogramme für den Gruppierungsvorgang beider Subsysteme	136
Abbildung 50: Typenbezogene Abdeckung der Aktivitäten von Entscheidungsprozessen	153
Abbildung 51: Typenbezogene Abdeckung von Prozessen des Logistikmanagements	154
Abbildung 52: Anwendungsspektrum von ML-Anwendungen im Logistikmanagement	156
Abbildung 53: Bedeutung der Problemlösungsfähigkeiten von ML	161
Abbildung 54: Bedeutung der logistischen Anwendungsbereiche von ML	163
Abbildung 55: Wirkungsdimensionen von ML im Logistikmanagement	164
Abbildung 56: Gründe für den Einsatz von ML im Logistikmanagement	170
Abbildung 57: Indikatoren für die Eignung von Anwendungsfällen zum Einsatz von ML	172
Abbildung 58: Vorgehen bei der Anforderungserhebung	175
Abbildung 59: Anforderungsgruppen	176
Abbildung 60: Autonomiestufen von ML-Anwendungen	179
Abbildung 61: Lernfähigkeit – Bewertung der Autonomiestufen	180
Abbildung 62: Entscheidungsfähigkeit – Bewertung der Autonomiestufen	181
Abbildung 63: Funktionen – Bewertung der Bedeutung	204
Abbildung 64: Qualitätseigenschaften – absolute Bewertung	204
Abbildung 65: Qualitätseigenschaften – relative Bewertung	207
Abbildung 66: Umfeldeigenschaften – absolute Bewertung	208
Abbildung 67: Umfeldeigenschaften – relative Bewertung	211
Abbildung 68: Priorisierung der geforderten Qualitäts- und Umfeldeigenschaften	213
Abbildung 69: Synthese der Teilergebnisse der Arbeit für Maßnahmenentwicklung	215
Abbildung 70: Gestaltungsansatz für den Einsatz von ML im Logistikmanagement	216
Abbildung 71: Handlungsfeld Strategie – Übersicht	219
Abbildung 72: Gegenüberstellung von Technologiepotenzial und betrieblichen Problemen	221
Abbildung 73: Vision und Strategie-Roadmap im ETA-Anwendungsfall	224
Abbildung 74: Handlungsfeld Ablauforganisation – Übersicht	226
Abbildung 75: Vorgehensmodell für die Auswahl und Umsetzung von ML-Anwendungen	229

Abbildung 76: Problemanalyse und Zielformulierung – Vorgehen	230
Abbildung 77: Steckbrief zur Auswahlentscheidung für ML-Anwendungen.....	232
Abbildung 78: Vorbereitung der Datenbasis – Vorgehen	240
Abbildung 79: Modellentwicklung – Vorgehen	247
Abbildung 80: Betriebliche Einführung – Vorgehen	251
Abbildung 81: Data-Pre-Check im ETA-Anwendungsfall	257
Abbildung 82: Anwendungssteckbrief im ETA-Anwendungsfall.....	259
Abbildung 83: Bewertung der vorhandenen Datenbasis im ETA-Anwendungsfall	261
Abbildung 84: Modellsteckbrief im ETA-Anwendungsfall.....	262
Abbildung 85: Funktionsprinzip des PoC für Anwendung im ETA-Anwendungsfall	263
Abbildung 86: Handlungsfeld Aufbauorganisation – Übersicht.....	266
Abbildung 87: Agile Organisationsstruktur des IT-Bereiches mittels Spotify-Modell	269
Abbildung 88: Handlungsfeld Mensch-Computer-Interaktion – Übersicht	274
Abbildung 89: Aufgabenverteilung zwischen ML-Anwendungen und Menschen	275
Abbildung 90: Veränderung des Aufgabenspektrums durch ML-Anwendungen	277
Abbildung 91: Maßnahmen zur Qualitätskontrolle von ML-Anwendungen	278
Abbildung 92: UI mit systemseitigen Zusatzinformationen im ETA-Anwendungsfall.....	280
Abbildung 93: Handlungsfeld Kompetenzmanagement – Übersicht.....	282
Abbildung 94: Anforderungen an das Qualifikationsprofil von Data Scientists	283
Abbildung 95: Personalisierung von ML-Anwendungen – Praxisbeispiel	286
Abbildung 96: User-Community-Ansatz zur Schulung der Nutzer	288
Abbildung 97: Handlungsfeld Datenmanagement – Übersicht	290
Abbildung 98: Aufbau der modularen Plattform für ML-Services	293
Abbildung 99: Bibliografische Auswertung der Datenbasis – Publikationsorgane.....	310
Abbildung 100: Bibliografische Auswertung der Datenbasis – Land der Publikation	310
Abbildung 101: Bibliografische Auswertung der Datenbasis – Jahr der Publikation.....	311

Tabellenverzeichnis

Tabelle 1: Beiträge und Implikationen der forschungsleitenden Theorien	29
Tabelle 2: Merkmale von komplexen Problemen	39
Tabelle 3: Eigenschaften von intelligenten Systemen im Sinne des totalen Turing-Tests	50
Tabelle 4: Typische Merkmalsausprägungen der KI-Paradigmen beim Lernprozess	56
Tabelle 5: Stärken und Schwächen der symbolischen und subsymbolischen KI	60
Tabelle 6: Kriterien zur Auswahl von Lernverfahren	69
Tabelle 7: Datenbereinigung der Antworten bei Onlinebefragung	89
Tabelle 8: Teilnehmer der Experteninterviews mit ML-Anwendungsfällen	92
Tabelle 9: Systematisierung des Forschungsstands und Einordnung der Arbeit	95
Tabelle 10: Zusammenfassung der Fallstudienforschung	122
Tabelle 11: Forschungstrends zu ML mit Auswirkungen auf das Untersuchungsfeld	124
Tabelle 12: Umfeldentwicklungen mit Auswirkungen auf das Untersuchungsfeld	129
Tabelle 13: Zusammenfassung der Typen für Problemlösungsfähigkeit	137
Tabelle 14: Zusammenfassung der Typen für die logistischen Entscheidungsprozesse	145
Tabelle 15: Relative Häufigkeit der Typen	157
Tabelle 16: Funktionen – Anforderungspräzisierung	177
Tabelle 17: Qualitätseigenschaften – Anforderungspräzisierung	183
Tabelle 18: Umfeldeigenschaften – Anforderungspräzisierung	191
Tabelle 19: Kriterien und Schritte der Validierung.....	218
Tabelle 20: Handlungsfeld Strategie – Erfüllung der Anforderungen.....	225
Tabelle 21: Komplexitätsreduzierung der ML-Anwendungen beim Prototyping	227
Tabelle 22: Quality Gates des Vorgehensmodells	228
Tabelle 23: Ablauf eines Feature-Engineering-Workshops.....	245
Tabelle 24: Handlungsfeld Ablauforganisation – Erfüllung der Anforderungen	265
Tabelle 25: Rollen und deren Funktionen in ML-Projekten	267
Tabelle 26: Handlungsfeld Aufbauorganisation – Erfüllung der Anforderungen.....	273
Tabelle 27: Handlungsfeld Mensch-Computer-Interaktion – Erfüllung der Anforderungen	281
Tabelle 28: Bewertung der Eigen- oder Fremdentwicklung von ML-Anwendungen	284
Tabelle 29: Schulungsinhalte zu ML	286
Tabelle 30: Handlungsfeld Kompetenzmanagement – Erfüllung der Anforderungen.....	289
Tabelle 31: Handlungsfeld Datenmanagement – Erfüllung der Anforderungen	295
Tabelle 32: Erfüllung der Anforderungen durch den Gestaltungsansatz	297
Tabelle 33: Übersichtsarbeiten mit Schnittmengen zum Untersuchungsfeld.....	309
Tabelle 34: Merkmale der ML-Anwendungen für Clusteranalyse	313
Tabelle 35: ML-Typologie mit repräsentativen Anwendungsfällen	314

Abkürzungsverzeichnis

5G	Fünfte Mobilfunkgeneration
AF	Anforderung
AGI	Artificial General Intelligence
AI	Artificial Intelligence
API	Application Programming Interfaces
APS	Advanced Planning and Scheduling
AutoML	Automated Machine Learning
AWS	Amazon Web Services
BA	Business Analytics
BDSG	Bundesdatenschutzgesetz
BI	Business Intelligence
BKM	Bedarfs- und Kapazitätsmanagement
BPMN	Business Process Model and Notation
CBV	Competence-based View
CI/CD	Continuous Integration / Continuous Delivery
CIO	Chief Information Officer
CRISP-DM	Cross Industry Standard Process for Data Mining
CSR	Corporate Social Responsibility
CTO	Chief Information Officer
DCV	Dynamic Capabilities View
DI	Dunn-Index
DL	Deep Learning
DLZ	Durchlaufzeit
DML	Distributed Machine Learning
DOI	Diffusion of Innovations
DSGVO	Datenschutz-Grundverordnung
DSS	Decision Support Systems
DT	Digital Twins
DTO	Digital Transformation Office
EIU	Eisenbahninfrastrukturunternehmen
EL	Ensemble Learning
EPK	Ereignisgesteuerte Prozesskette
ERP	Enterprise-Resource-Planning
ESB	Enterprise Service Bus
ET	Entscheidungsträger
ETA	Estimated Time of Arrival
ETL	Extract, Transform, Load
EVL	Evolutionary Learning
EVU	Eisenbahnverkehrsunternehmen

FMEA	Fehlermöglichkeits- und Einflussanalyse
FML	Federated Machine Learning
GA	Genetische Algorithmen
GAN	Generative Adversarial Networks
GPS	Global Positioning System
GPU	Graphics Processing Unit
HCI	Human-Computer-Interaction (Mensch-Computer-Interaktion)
HDFS	Hadoop Distributed File System
HF	Handlungsfeld
HITL	Human-in-the-Loop
HOTL	Human-on-the-Loop
IaaS	Infrastructure-as-a-Service
IaC	Infrastructure as Code
IML	Informed Machine Learning
IoT	Internet of Things
IS	Informationssystem
IT	Informationstechnik
KDD	Knowledge Discovery in Databases
KI	Künstliche Intelligenz
KMU	Kleine und mittlere Unternehmen
KNN	Künstlich neuronale Netze
KV	Kombinierter Verkehr
LAB	Beschaffungs- und Absatzplanung
LDL	Logistikdienstleister
LkSG	Lieferkettensorgfaltspflichtengesetz
LM	Lieferantenmanagement
MAE	Mean Absolute Error
MBV	Market-based View
MES	Manufacturing Execution System
ML	Maschinelles Lernen / Machine Learning
MLaaS	Machine-Learning-as-a-Service
MRP	Material Requirements Planning
MSE	Mean Squared Error
MTO	Mensch-Technik-Organisation
MVP	Minimum Viable Prototype
NC	Nonconformity-Material
NDA	Non-Disclosure Agreement
NLP	Natural Language Processing
NN	Neuronale Netze
NSGA-II	Non-dominated Sorting Genetic Algorithm II
OEE	Overall Equipment Effectiveness (Gesamtanlageneffektivität)
OR	Operations Research

OTD	On Time Delivery
PCA	Principal Components Analysis
PM	Prozessmonitoring
PoC	Proof-of-Concept
PPS	Produktionsplanung und -steuerung
QML	Quantum Machine Learning
QPU	Quantum Processing Unit
RBV	Resource-based View
RE	Requirements Engineering
RFID	Radio-Frequency Identification
RL	Reinforcement Learning
RMSE	Root Mean Square Error
RPA	Robot Process Automation
S&OP	Sales and Operations Planning
SaaS	Software-as-a-Service
SCM	Supply Chain Management
SCP	Supply Chain Planning
SCPM	Supply Chain Performance Management
SCRM	Supply Chain Risk Management
SEMMA	Sample, Explore, Modify, Model, Assess
SL	Supervised Learning
SLA	Systematische Literaturanalyse
SSL	Semi-supervised Learning
SVM	Support Vector Machine
TDSP	Team Data Science Process
TL	Transfer Learning
TM	Transportmanagement
TMS	Transport Management System
TOE	Technology-Organization-Environment
TPA	Team Process Algorithm
TPC	Technology-to-Performance Chain
TPU	Tensor Processing Unit
TRL	Technology Readiness Level
TTF	Task-Technology-Fit
UI	User Interface (Benutzerschnittstelle)
USL	Unsupervised Learning
VRIO	Value, Rarity, Inimitability, Organisational specificity
XAI	Explainable Artificial Intelligence

1 Einleitung

Zu Beginn dieses einleitenden Kapitels werden die **Motivation und Relevanz** der vorliegenden Arbeit mit Blick auf den Status Quo in der Praxis und Wissenschaft dargestellt (Kapitel 1.1). Dies mündet in der Formulierung des **Forschungsziels** der Arbeit, welches wiederum durch mehrere Teilfragen repräsentiert wird (Kapitel 1.2). Das zum Erreichen des Ziels gewählte **Forschungsdesign** wird im Anschluss erläutert, wozu eine wissenschaftstheoretische Einordnung und eine Vorstellung des Forschungsprozesses, einschließlich der Offenlegung des Vorverständnisses des Autors, erfolgt (Kapitel 1.3). Abschließend wird prägnant der **Aufbau** der Arbeit beschrieben (Kapitel 1.4).

1.1 Ausgangssituation und Motivation

Der Einsatz von Technologien stellt einen zentralen Treiber für die Steigerung der Wettbewerbsfähigkeit von Unternehmen dar.¹ Mittels technologiebasierter Produkt- und Prozessverbesserungen lassen sich Leistungs- und Qualitätssteigerungen sowie neue Marktpotenziale erschließen.² Insbesondere Schlüsseltechnologien³ wird eine hohe Bedeutung für die langfristige Positionierung im Wettbewerb zuteil, weshalb diese von Unternehmen hinsichtlich eines möglichen Einsatzes zu prüfen sind.⁴ Bedeutende Schlüsseltechnologien des 21. Jahrhunderts werden unter dem Begriff der **Künstlichen Intelligenz (KI)** bzw. **Artificial Intelligence (AI)** subsumiert.⁵ In Analogie zur menschlichen Kognition erfordern definitionsgemäße „künstlich intelligente“ Systeme neben der Wahrnehmung von Informationen, u. a. durch Verstehen von Sprache, sowie der Ausübung von Handlungen auch die Fähigkeit zum zielgerichteten Erwerb von Wissen für die Lösung von Problemen im Sinne eines **maschinellen Lernens**.⁶

Zur Realisierung dieser systemseitigen Lernfähigkeit hat sich mit dem **Machine Learning (ML)** ein eigenständiger Forschungs- und Technologiebereich im Kontext von KI herausgebildet. Im Gegensatz zu einer manuellen Codierung der jeweiligen Lösungswege, z. B. mittels Regeln oder Ontologien, wird das benötigte Wissen bei ML automatisch durch die jeweiligen Systeme erworben. Dies erfolgt durch den Einsatz von **Lernverfahren** in Form von Algorithmen, welche empirische Zusammenhänge zur Problemlösung auf Grundlage von übergebenen Daten zum

¹ Vgl. Klappert et al. (2011), S. 5 f.

² Vgl. Haag et al. (2011), S. 323

³ Schlüsseltechnologien üben „einen deutlich überragenden Einfluss auf die Wettbewerbsfähigkeit“ von Unternehmen aus. Sie befinden sich in dem jeweiligen Marktsegment derzeit in der Wachstumsphase, d. h. sie weisen einen potenziell hohen Nutzen mit einem breiten Anwendungsspektrum auf, sind aber nicht für alle Unternehmen gleichermaßen zugänglich. Vgl. Sommerlatte, Deschamps (1985), S. 50 ff.

⁴ Vgl. Bullinger (1994), S. 6

⁵ Vgl. Deutscher Bundestag (2020), S. 3

⁶ Vgl. Harnad (1991), S. 43 f.

jeweiligen Anwendungsbereich eigenständig ermitteln.⁷ Durch die Bewertung der erzielten Ergebnisse anhand einer ebenfalls vorgegebenen Leistungsmetrik führt dieser Ansatz zu einer kontinuierlichen Verbesserung des Wissens, d. h. zur einer effektiveren und effizienteren Problemlösung.⁸ Die Realisierung einer systemseitigen Lernfähigkeit mittels ML entspricht einem Paradigmenwechsel in der Informatik und ermöglicht es den Systemen, das eigene Verhalten bei der Ausführung der Tätigkeiten an veränderte Bedingungen anzupassen.⁹ Somit bildet ML auch die technische Grundlage für die Realisierung einer **systemseitigen Autonomie**.¹⁰

Auch wenn die Forschungsaktivitäten bis in die 1950er Jahre zurückreichen, war ML lange ein eher wissenschaftlich geprägtes Thema. Erst seit den 2010er Jahren konnte die Nutzungsmöglichkeit abseits der Forschung für viele Anwendungsbereiche realisiert werden. Dies geht insbesondere auf die verbesserten technischen Voraussetzungen zurück, wozu die Zunahme der **Datenmenge** entsprechend der voranschreitenden Digitalisierung sowie der Anstieg der verfügbaren **Rechenleistung** zählen, u. a. durch die Nutzung von Cloud Computing. Durch eine Weiterentwicklung der Lernverfahren und eine Bereitstellung nutzerfreundlicher Entwicklungsumgebungen, wie Python und R, konnten zudem die Fähigkeiten von ML weiter verbessert sowie gleichzeitig die Kosten und die benötigte Zeit für die Umsetzung reduziert werden.¹¹

Diese verbesserten Möglichkeiten haben in den letzten Jahren zu größeren – auch teils öffentlichkeitswirksamen Erfolgen – von ML geführt. Viele ML-Systeme weisen bereits in vielerlei Hinsicht einen **Leistungsvorsprung gegenüber dem Menschen** auf. Dazu gehören eine höhere Rechengeschwindigkeit, umfassendere Speichermöglichkeiten sowie die Möglichkeiten zur Erkennung komplexer Zusammenhänge und zur Verarbeitung einer höheren Informationsvielfalt.¹² Mittlerweile wird daher von der sog. **zweiten KI-Welle** gesprochen, die eine Ablösung der manuellen Programmierung von Wissen in Systemen zur Lösung von Problemen adressiert.¹³ Der durch ML induzierte Bedeutungsanstieg von KI zeigt sich – neben einer oft synonymen Verwendung beider Begriffe im öffentlichen Diskurs – auch in der politischen Resonanz, die zur Formulierung von dedizierten KI-Strategien in vielen Ländern geführt hat.¹⁴ Die praktische Nutzbarkeit von ML bzw. KI geht zudem mit einem sehr hohen wirtschaftlichen Potenzial einher. Demnach soll weltweit aus der Nutzung und Vermarktung von KI-Systemen bis

⁷ Vgl. Murphy (2012), S. 1; Alpaydin (2010), S. 3

⁸ Vgl. Simon (1983), S. 28

⁹ Vgl. Mitchell (1997), S. 2

¹⁰ Vgl. Wahlster (2017), S. 410. Autonome Systeme grenzen sich definitorisch von automatischen bzw. automatisierten Systemen ab, welche nur in der Lage sind, nach von Menschen vorgegebenen Regeln zu handeln. Vgl. Heßler (2019), S. 235 f.

¹¹ Vgl. Zhang et al. (2021), S. 47 ff., 62 ff.

¹² Vgl. Mainzer (2018), S. 221

¹³ Die Einteilung der KI-Forschung in bisher zwei große Wellen geht auf die US-Behörde „Defense Advanced Research Projects Agency“ zurück. Vgl. Fouse et al. (2020), S. 6

¹⁴ Als Beispiel ist die durch die Bundesregierung initiierte KI-Strategie aus dem Jahre 2018 zu nennen, welche 2020 novelliert wurde. Vgl. Deutscher Bundestag (2020)

zum Jahre 2030 ein Umsatz von 15,7 Billionen US-Dollar entstehen.¹⁵ Der Anteil für Deutschland wird auf 430 Milliarden geschätzt, was einem Anstieg von ca. 11 % des Bruttoinlandsprodukts entspricht.¹⁶

Für die Nutzung von ML im betrieblichen Kontext ergibt sich ebenfalls eine Vielzahl von Möglichkeiten. Die in diesem Zusammenhang entwickelten Artefakte werden aufgrund ihrer systemseitigen Lernfähigkeit als „maschinell lernende Systeme“ oder allgemein als **Lernende Systeme** bezeichnet.¹⁷ Hierbei kann es sich zum einen um Systeme handeln, die primär zur „physischen“ Verrichtung von Aktionen eingesetzt werden, wobei es sich gemäß dem äußeren Erscheinungsbild um Maschinen, Roboter, Fahrzeuge o. ä. handelt. Zum anderen können die Systeme aber auch für die Unterstützung bzw. Ausführung von übergeordneten **Entscheidungsprozessen** verwendet werden, wobei es sich in diesen Fällen um Softwaresysteme handelt. Diese zweite Gruppe von Lernenden Systemen wird in der vorliegenden Arbeit unter dem Begriff der **ML-Anwendungen** zusammengefasst.

Große Potenziale für den Einsatz von ML-Anwendungen in Entscheidungsprozessen werden für das **Logistikmanagement**, d. h. für logistische Planungs-, Steuerungs- und Kontrollaktivitäten¹⁸, konstatiert.¹⁹ Demnach wird ML als Schlüsseltechnologie für die **digitale Transformation** dieses Bereiches angesehen, mit der langfristig die Vision einer „intelligenten Logistik“ realisierbar ist (siehe Abbildung 1).²⁰ Durch die Nutzung von ML in Verbindung mit weiteren digitalen Technologien sollen komplexe logistische Prozesse bzw. gesamte Wertschöpfungs-systeme ganzheitlich, kundenorientiert und in Echtzeit gestaltet werden können sowie (semi-)autonom ausführbar sein.²¹ Diese Bedeutung für das Logistikmanagement resultiert v. a. aus den stetig steigenden Anforderungen der Kunden an eine kosten- und zeiteffiziente logistische Leistungserstellung, die zudem zuverlässig und hochflexibel erfolgen soll, woraus sich die Notwendigkeit der Ausführung **schneller und optimaler Entscheidungen** ergibt.²² Gleichzeitig sehen sich die Entscheidungsträger in der Logistik mit einer hohen Komplexität der zugrundeliegenden Probleme konfrontiert, welche auch die bereits eingesetzten entscheidungsunterstützenden Systeme vor Herausforderungen stellt. Demnach müssen bei den logistischen Planungs-, Steuerungs- und Kontrollaktivitäten zur Gestaltung und Koordination von unternehmensinternen und -übergreifenden Material- und Informationsflüssen aufgrund der Querschnittsfunktion der Logistik eine Vielzahl von Parametern berücksichtigt werden. Durch den fehlenden Zugang zu vielen Informationen und der Abhängigkeit vom Verhalten Dritter liegt dabei in vielen logistischen Entscheidungssituationen eine hohe Unsicherheit vor.²³

¹⁵ Vgl. PwC (2017), S. 4 f. Die Lernfähigkeit der hier betrachteten Systeme wird hervorgehoben.

¹⁶ Vgl. PwC (2018), S. 12. Die Lernfähigkeit der hier betrachteten Systeme wird hervorgehoben.

¹⁷ Vgl. Spath (2018), S. 506; Acatech (2021)

¹⁸ Vgl. Pfohl (2016), S. 22 f.

¹⁹ Vgl. BVL (2018), S. 2; Straube et al. (2020b), S. 59 f.; Kersten et al. (2017), S. 12; Jordan, Mitchell (2015), S. 255

²⁰ Vgl. Straube (2019), S. 9

²¹ Vgl. Straube (2019), S. 1

²² Vgl. Handfield et al. (2013), S. 39

²³ Vgl. Gupta, Maranas (2003), S. 1219

Außerdem müssen häufig verschiedene Ziele der involvierten Stakeholder und Unternehmensfunktionen, die sich teilweise konfliktär gegenüberstehen, bei der Problemlösung in Einklang gebracht werden.²⁴ Diese inhärente Komplexität wird durch die zunehmende globale Vernetzung von logistischen Netzwerken und die steigende Vielfalt von Produkten erhöht.²⁵




Abbildung 1: Entwicklungsstufen der digitalen Transformation der Logistik²⁶

Trotz der potenziell hohen Bedeutung zeigt sich ein **geringer Umsetzungsstand** von ML-Anwendungen in der logistischen Praxis. Demnach kann kein Unternehmen in Deutschland einen produktiven Einsatz dieser Systeme in weiten Teilen des jeweiligen Logistikbereiches vorweisen.²⁷ Der Großteil der Unternehmen verfügt vielmehr bisher über keinerlei Anwendungen.²⁸ Gleichzeitig ist aber in anderen Unternehmensbereichen und Branchen bereits ein höherer Fortschritt festzustellen.²⁹ Noch vor einer etwaigen fehlenden Verfügbarkeit technologie-spezifischer Voraussetzungen in den Unternehmen kann als bedeutende Ursache für diesen Umsetzungsstand deren **fehlendes Wissen** zum Einsatz von ML identifiziert werden, was sowohl geeignete logistische Anwendungsmöglichkeiten und damit erzielbare Nutzenpotenziale als auch geeignete Maßnahmen zur Schaffung der benötigten Voraussetzungen umfasst.³⁰ Dies führt dazu, dass sich insgesamt nur ca. ein Viertel der Unternehmen zur erfolgreichen Umsetzung von ML in der Logistik befähigt fühlen, wobei nur jedes zehnte Unternehmen diesem Sachverhalt gänzlich zustimmt (siehe Abbildung 2). Selbiges Bild zeigt sich auch im Falle von Unternehmen mit bereits bestehenden Anwendungen (sog. Adopter³¹). Diese sind mit der Herausforderung einer Skalierung ihrer oft prototypischen oder sich auf Pilotanwendungsfälle beschränkenden produktiven Systeme konfrontiert. Die fehlende Überwindung dieser kritischen Kluft zwischen dem Beweis der technischen Machbarkeit in einem begrenzten Anwendungsbereich und der Generierung langfristiger betriebswirtschaftlicher Mehrwerte, welche im

²⁴ Vgl. Gudehus (2010), S. 77 f.

²⁵ Vgl. Handfield et al. (2013), S. 8

²⁶ Eigene Darstellung in Anlehnung an Straube (2019), S. 47

²⁷ Vgl. Böttcher et al. (2017), S. 36

²⁸ Vgl. BVL (2018), S. 1.

²⁹ Vgl. BMWI (2020), S. 3

³⁰ Diese und die folgenden Aussagen beziehen sich auf Ergebnisse der empirischen Untersuchung der vorliegenden Arbeit, welche in Ermangelung bestehender Analysen zum Einsatz von ML im Logistikmanagement durchgeführt wurde. Eine detaillierte Ergebnisdarstellung findet sich in Kapitel 4.2.

³¹ Für Unternehmen mit bestehenden prototypischen und/oder produktiven Anwendungen wird im weiteren Verlauf der Begriff der Adopter genutzt. Vgl. Gerpott (1999), S. 121. Die übrigen Unternehmen werden als Non-Adopter bezeichnet.

Kontext von ML bzw. von KI im Allgemeinen auch als **AI Chasm** bezeichnet wird, führt bisher zum Scheitern vieler Anwendungen.




Abbildung 2: Voraussetzungen in Unternehmen für den Einsatz von ML in der Logistik³²

Aus der Diskrepanz zwischen der hohen postulierten Bedeutung von ML für das Logistikmanagement und dem bisher geringen Umsetzungsstand in der Praxis – sowohl in Bezug auf konkrete Anwendungen als auch hinsichtlich der Kenntnisse zum erfolgreichen Einsatz – lässt sich ein Handlungsbedarf für die Wissenschaft ableiten. Bei der Analyse des aktuellen Forschungsstands ist jedoch festzustellen, dass die zu ML verfügbaren Veröffentlichungen größtenteils der Informatik zuzuordnen sind und lediglich **entwicklungsseitige Fragestellungen** aufgreifen. Dies reicht von einer Auseinandersetzung mit technischen Grundlagen von ML in Form der Lernverfahren, über die methodische Unterstützung von Entwicklungsprozessen bis hin zur Vorgabe von diesbezüglichen Vorgehensmodellen, wobei letztere zumeist für datenbasierte Vorhaben im Allgemeinen gestaltet sind. Entsprechend der langen Historie von ML reichen diese informationstechnischen Veröffentlichungen bis in die 1960er Jahre zurück. Zur Gestaltung des **Einsatzes von ML im betrieblichen Kontext** existiert dagegen branchenübergreifend nur wenig wissenschaftliche Literatur. Damit verbundene Fragestellungen werden erst seit Ende der 2010er Jahre in der Forschung diskutiert. Lediglich für KI oder digitale Technologien in der Gesamtheit, d. h. ohne eine explizite Betrachtung der Eigenschaften und Anforderungen von ML, finden sich einzelne Veröffentlichungen. Für den spezifischen Anwendungsbereich des Logistikmanagements bzw. der Logistik im Allgemeinen wurde dieses Forschungsfeld allerdings bisher **weder für ML noch für KI erschlossen**. Dies gilt sowohl für eine Herausarbeitung des Anwendungsspektrums und damit verbundener Potenziale als auch für die Bereitstellung geeigneter Maßnahmen zur Befähigung von Unternehmen für den Einsatz von ML-Anwendungen in diesem Bereich.³³

³² Eigene Darstellung

³³ Eine detaillierte Analyse und Systematisierung des gegenwärtigen Forschungsstands werden in Kapitel 4.1 vorgenommen.

1.2 Zielsetzung und Untersuchungsfeld der Arbeit

Entsprechend der hohen Potenziale für das Logistikmanagement stehen Unternehmen vor der Aufgabe, Machine Learning in Form geeigneter Anwendungen für ihre Organisation zur Erzielung von Wettbewerbsvorteilen nutzbar zu machen. Der Erfolg und die Geschwindigkeit des damit verbundenen Umsetzungsprozesses sind von vielen Faktoren abhängig, wozu u. a. die Fähigkeiten der betrachteten Technologie, aber auch die technischen, sozialen und organisatorischen Voraussetzungen der jeweiligen Unternehmen sowie deren externe Rahmenbedingungen zählen.³⁴ Ein angestrebter Einsatz ist daher nicht zufallsbasiert durchzuführen, sondern bedarf einer systematischen Gestaltung unter Berücksichtigung von technologie- und domänenspezifischen Faktoren.³⁵

Ausgehend vom identifizierten Forschungsbedarf ist es das Ziel der vorliegenden Arbeit, Unternehmen zum erfolgreichen Einsatz von Machine Learning im Logistikmanagement zu befähigen, um damit einen Beitrag zur langfristigen Steigerung von deren Wettbewerbsfähigkeit zu leisten. Dazu wird ein **Gestaltungsansatz** entwickelt, der als Unterstützungsinstrument für Unternehmen fungieren soll, indem er geeignete Handlungsempfehlungen für die Gestaltung von ML-Anwendungen und von deren benötigtem Umfeld bereitstellt. Die primäre Forschungsfrage der Arbeit lautet daher:

Wie kann der Einsatz von ML-Anwendungen im Logistikmanagement erfolgreich von Unternehmen gestaltet werden?

Zum Erreichen dieses Forschungsziels werden fünf sekundäre Forschungsfragen formuliert. Die erste sekundäre Forschungsfrage adressiert die Erfassung der theoretischen Grundlagen für die Arbeit durch eine Charakterisierung und Abgrenzung der prozessualen und technischen Dimensionen des Untersuchungsfeldes in Form des Logistikmanagements und von ML. Hierbei soll ebenfalls eine Auseinandersetzung mit assoziierten Themenbereichen in Form von Entscheidungsprozessen und -techniken sowie der Künstlichen Intelligenz erfolgen.

Wie können ML-Anwendungen im Kontext des Logistikmanagements beschrieben und

I. abgegrenzt werden? Welche wesentlichen Konzepte und Methoden sind hierbei zu berücksichtigen?

Im Rahmen der zweiten sekundären Forschungsfrage soll der Umsetzungsstand von ML-Anwendungen im Logistikmanagement aus wissenschaftlicher und praktischer Perspektive untersucht werden. Zur Berücksichtigung unterstützender und hemmender Faktoren sind darüber hinaus zukünftige Entwicklungen mit Relevanz für das Untersuchungsfeld zu ermitteln.

Wie lässt sich der Stand in Forschung und Praxis zum Einsatz von ML-Anwendungen im

II. Logistikmanagement charakterisieren und welche zukünftigen Entwicklungen sind für das Untersuchungsfeld zu erwarten?

³⁴ Vgl. DePietro et al. (1990), S. 153

³⁵ Vgl. Ulich (2013), S. 5 f.; Baker (2012), S. 236

Die Anwendungsmöglichkeiten von ML im Logistikmanagement sollen im Rahmen der dritten sekundären Forschungsfrage erschlossen werden. Dazu gehört eine Systematisierung bestehender und zukünftiger Anwendungen, aber auch eine Ermittlung der Auswirkungen für logistische Entscheidungsprozesse, einschließlich daraus resultierender Nutzenpotenziale und Risiken für Unternehmen.

Wie kann das Anwendungsspektrum von ML im Logistikmanagement systematisiert und
III. bewertet werden? Welche Implikationen ergeben sich für die Ausführung von logistischen Entscheidungsprozessen?

Zur Ermittlung geeigneter Maßnahmen bedarf es einer vorausgehenden Erhebung von domänenspezifischen Anforderungen an den Einsatz von ML-Anwendungen. Dies wird durch die vierte sekundäre Forschungsfrage adressiert:

Welche Anforderungen bestehen an den erfolgreichen Einsatz von ML-Anwendungen im
IV. Logistikmanagement und wie ist deren Umsetzungsstand in der Praxis?

Unter Berücksichtigung der erzielten Ergebnisse sollen im Rahmen der fünften sekundären Forschungsfrage geeignete Maßnahmen für den erfolgreichen Einsatz von ML im Logistikmanagement erforscht und zu einem Gestaltungsansatz strukturiert werden.

Welche Maßnahmen eignen sich für einen erfolgreichen Einsatz von ML-Anwendungen
V. im Logistikmanagement und wie lassen sich diese in einen übergreifenden Gestaltungsansatz integrieren?

Für das Erreichen des Forschungsziels wird das Untersuchungsfeld der vorliegenden Arbeit hinsichtlich verschiedener Dimensionen eingegrenzt (siehe Abbildung 3). Eine zentrale Einschränkung bezieht sich auf das betrachtete Aufgabenspektrum der Logistik für den Einsatz von ML. Wie im Rahmen der Zielstellung formuliert, werden lediglich Planungs-, Steuerungs- und Kontrollaktivitäten, d. h. **logistische Entscheidungsprozesse**, betrachtet. Ausführende Tätigkeiten zur logistischen Leistungserstellung, einschließlich einer „physischen“ Verrichtung, finden demnach keine Berücksichtigung.³⁶ Entsprechend dieser Fokussierung handelt es sich bei den betrachteten technischen Systemen im Sinne des Erscheinungsbildes primär um **Softwaresysteme** und nicht um Maschinen, Roboter, Fahrzeuge o. ä. Das adressierte Prozessspektrum erstreckt sich dabei über die Beschaffungs-, Produktions- und Distributionslogistik bis hin zum Vertrieb. Als organisationales Bezugsobjekt fungieren **Industrieunternehmen**, die über einen eigenen Logistikbereich verfügen, wobei keine Einschränkungen hinsichtlich einer Branche vorgenommen werden. Aufgrund hoher prozessualer Überschneidungen wird zudem eine partielle Übertragbarkeit der Ergebnisse auf andere Akteure im logistischen Umfeld in Form von Logistikdienstleistern (LDL) und Handelsunternehmen angenommen.

³⁶ Diese Tätigkeiten werden auch als Fulfillment bezeichnet. Vgl. Straube (2004), S. 136

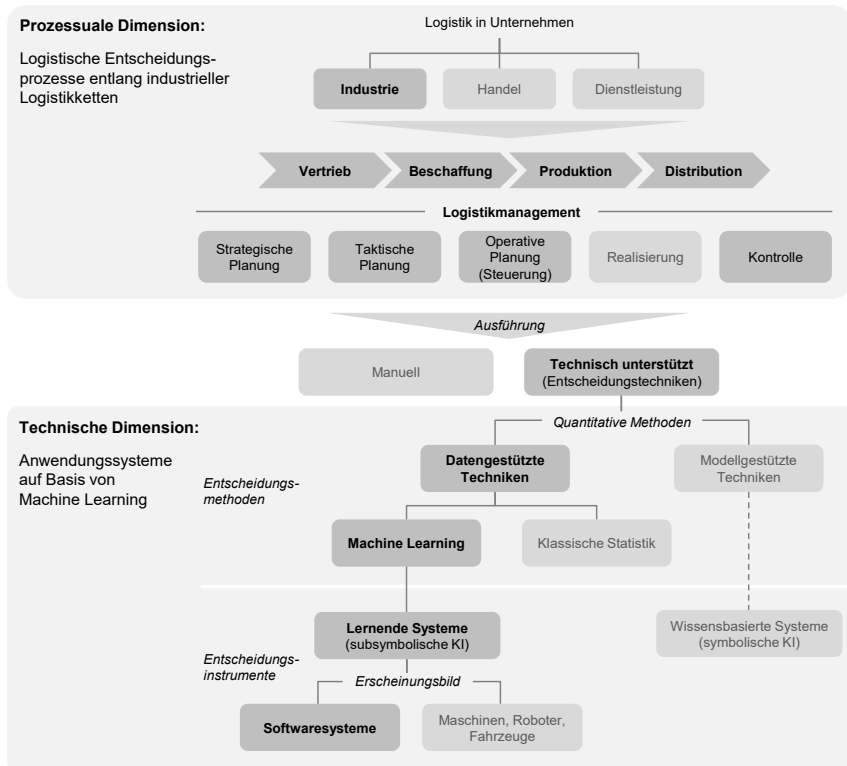


Abbildung 3: Prozessuale und technische Dimension des Untersuchungsfelds³⁷

Für die Entwicklung von Maßnahmen im Rahmen des Gestaltungsansatzes erfolgt eine zusätzliche thematische Eingrenzung. Demnach wird eine Exklusion von **ethischen und rechtlichen Fragestellungen** im Zusammenhang mit dem Einsatz von ML vorgenommen, da es sich hierbei um ein eher logistikunspezifisches Untersuchungsfeld handelt, welches von Forschungsarbeiten in anderen Disziplinen zu adressieren ist.³⁸ Ferner wird auf eine **Wirtschaftlichkeitsbetrachtung** des Technologieeinsatzes verzichtet, d. h. auf eine Quantifizierung des Nutzens und Aufwands einzelner Anwendungen und Umsetzungsmaßnahmen. Dies geht insbesondere auf die Komplexität bei der Messung von technologieinduzierten Effekten zurück, welche ebenfalls ein separates Untersuchungsfeld darstellt. Stattdessen wird in der Arbeit eine

³⁷ Eigene Darstellung. Eine detaillierte Abgrenzung und Systematisierung der prozessualen und technischen Dimension des Untersuchungsfelds erfolgt in Kapitel 2.

³⁸ Rechtliche und ethische Fragestellungen beziehen sich u. a. auf die algorithmusbasierte Entscheidungsfindung, inkl. juristischer Fragestellungen der Verantwortung und Haftung, auf die mögliche Diskriminierung und Voreingenommenheit (Bias) der Systeme, den Umgang mit geistigem Eigentum und den Datenschutz sowie die zukünftige Rolle des Menschen und seiner Zusammenarbeit mit intelligenten Systemen. Eine Übersicht dazu findet sich in Rodrigues et al. (2019), S. 40 ff.

qualitative Bewertung vorgenommen, u. a. durch die Erhebung von wirtschaftlichen Nutzenpotenzialen. Eine weitere Einschränkung ergibt sich aus der eingenommenen Betrachtungsebene bei der Untersuchung von **Aufgaben der Informationstechnik (IT)** für die Entwicklung und den Betrieb von ML-Anwendungen sowie von dafür notwendigen Software- und Hardwarekomponenten. Diese werden in ihrer Gesamtheit dargestellt, jedoch nicht inhaltlich vertieft. Zudem wird hierbei ein Fokus auf ML-spezifische Maßnahmen eingenommen, sodass tendenziell „klassische“ IT-Aktivitäten nur tangiert werden, z. B. die Schnittstellenprogrammierung sowie die Systemintegration und -administration. Bis auf die genannten Themen wird keine weitere vorausgehende Eingrenzung vorgenommen. Stattdessen liegt der Arbeit der Anspruch zugrunde, zur initialen Erschließung des Forschungsfeldes möglichst einen **Gesamtüberblick zu relevanten Gestaltungsbereichen** für den Einsatz von ML im Logistikmanagement bereitzustellen, um damit einen Ansatzpunkt für weitere Arbeiten mit einer Fokussierung auf einzelne identifizierte Bereiche zu bieten.

1.3 Forschungsdesign

1.3.1 Wissenschaftstheoretische Einordnung

Grundlage für die Konzeption des Forschungsdesigns der vorliegenden Arbeit ist deren Einordnung in das wissenschaftliche Spektrum. Wissenschaft wird dabei als „*intersubjektiv überprüfbare Untersuchung von Tatbeständen und die auf ihr beruhende, systematische Beschreibung und – wenn möglich – Erklärung der untersuchten Tatbestände*“ definiert.³⁹ Sowohl der Prozess zum systematischen Gewinn von Erkenntnissen („Wissenschaft als Tätigkeit“) als auch die resultierenden Ergebnisse, welche in einem Begründungszusammenhang stehen („Wissenschaft als Ergebnis“), sind Teil des wissenschaftlichen Verständnisses.⁴⁰ Bei einer Systematisierung kann auf oberster Ebene eine Einteilung in Formal- und Realwissenschaften vorgenommen werden. Während Formalwissenschaften, wie z. B. die Philosophie, Logik und Mathematik, die Konstruktion und Verwendung von Zeichensystemen und Regeln umfassen, beinhalten **Realwissenschaften** die Beschreibung, Erklärung und Gestaltung empirisch wahrnehmbarer Ausschnitte aus der Realität.⁴¹ Die Realwissenschaften lassen sich wiederum entsprechend ihrer Aufgabenstellung in reine und angewandte Wissenschaften (sog. Grundlagen- und Handlungswissenschaften) unterteilen, wobei keine invariante Trennung zwischen beiden besteht.⁴²

Ein wesentlicher Unterschied dieser beiden Wissenschaftsarten kann jedoch für den Zusammenhang festgemacht werden, in dem die jeweils adressierten Problemstellungen entstehen. Ausgangspunkt der Grundlagenwissenschaften, zu den u. a. die Naturwissenschaften gehö-

³⁹ Körner (1980), S. 726 f.

⁴⁰ Vgl. Raffée (1993), S. 13

⁴¹ Vgl. Ulrich, Hill (1979), S. 163

⁴² Vgl. Raffée (1993), S. 15

ren, sind theoretische Zusammenhänge, die im Rahmen des Forschungsprozesses unter Beobachtung der Realität erklärt und geprüft werden.⁴³ Der Forschungsprozess der angewandten Wissenschaften beginnt dagegen mit einem **Problem in der Praxis**, für welches Lösungen gefunden werden sollen, sodass eine „neue Wirklichkeit“ entsteht.⁴⁴ Diese Ergebnisse sind bei den angewandten Wissenschaften im zukünftigen Anwendungszusammenhang zu prüfen.⁴⁵ Stellvertreterdisziplinen dieser Wissenschaftsarten sind u. a. die Ingenieurwissenschaften sowie die Sozialwissenschaften, zu denen auch die Betriebswirtschaftslehre gehört.⁴⁶

Das Problem einer bisher fehlenden Befähigung der Unternehmen zum Einsatz von ML im Logistikmanagement, welches durch die vorliegende Untersuchung adressiert wird, entstammt der Praxis, sodass die Arbeit den **angewandten Wissenschaften** zugeordnet werden kann. Die angestrebten Aktivitäten zur Gestaltung des Technologieeinsatzes durch geeignete Maßnahmen sind Teil des interdisziplinären Aufgabenspektrums des Technologiemanagements, welches u. a. wirtschaftliche und technische Inhalte verbindet.⁴⁷ Die Arbeit lässt sich daher an der Schnittstelle **zwischen den Ingenieurwissenschaften und der Betriebswirtschaftslehre** verorten. Die Beschreibung und Erklärung von ML, inkl. den Fähigkeiten und Anwendungsbereichen, sowie die technischen Maßnahmen des Gestaltungsansatzes unterliegen dem Verständnis der Ingenieurwissenschaften. Genutzte betriebswirtschaftliche Erklärungsansätze sind u. a. die Auswirkungen von ML-Anwendungen auf das Logistikmanagement sowie die primär organisatorischen und sozialen Maßnahmen.

1.3.2 Forschungskonzeption

Zur Realisierung des Forschungsziels und unter Berücksichtigung bisheriger wissenschaftlicher Erkenntnisse bedarf es eines geeigneten Forschungskonzeptes, welches wesentliche Prämissen der jeweiligen Arbeit offenlegt.⁴⁸ Entsprechend der ausgeprägten Interdisziplinarität und der hohen Anwendungsorientierung wird der vorliegenden Untersuchung die **systemorientierte Managementlehre** nach *Ulrich (2001)* zugrunde gelegt. Dieser Ansatz begreift Unternehmen als soziotechnische Systeme, welche – analog zum Vorgehen in den Ingenieurwissenschaften – ausgehend von einem Praxisproblem im Rahmen des Forschungsprozesses zu gestalten sind.⁴⁹ In Hinblick auf die Zielsetzung der vorliegenden Arbeit gibt dieses mehrdimensionale Verständnis von Unternehmen einen Hinweis auf die Gestaltung von sozialen und technischen Elementen bei der Einführung neuer Technologien. Der **Gestaltungsanspruch** zur Erzeugung neuer Realitäten mittels möglicher Handlungsalternativen in Form von Modellen und Regeln, welcher über die Erklärung und Beschreibung bzw. Prognose von Realitäten

⁴³ Vgl. Ulrich (1984), S. 202

⁴⁴ Vgl. Ulrich (1984), S. 203

⁴⁵ Vgl. Ulrich (1984), S. 207

⁴⁶ Vgl. Ulrich, Hill (1979), S. 164; Chmielewicz (1994), S. 30 f.

⁴⁷ Vgl. Bullinger (1994), S. 43; Klappert et al. (2011), S. 7

⁴⁸ Vgl. Chmielewicz (1994), S. 8 ff.

⁴⁹ Vgl. Ulrich (2001), S. 25 f.

hinausgeht, ist von Forschungsarbeiten im Kontext des systemtheoretischen Ansatzes zu berücksichtigen.⁵⁰ Darüber hinaus bedarf es einer Prüfung der entworfenen Lösungen auf Anwendbarkeit in der Realität.⁵¹ Beiden Forderungen wird in der vorliegenden Arbeit Rechnung getragen, indem zum einen neben der Beschreibung der Problemstellung aus der Praxis und deren Erklärungen im wissenschaftlichen und praktischen Kontext auch Gestaltungsempfehlungen entwickelt werden. Zum anderen werden diese Lösungen hinsichtlich ihrer Eignung in der Praxis untersucht.

Als korrespondierendes Rahmenwerk für die Gestaltung des Forschungsprozesses erfolgt zudem eine Orientierung am idealtypischen **Vorgehen für angewandte Wissenschaften** nach *Ulrich (1981)*. Ausgehend von einer Beobachtung und Beschreibung der praktischen Problemstellung sieht dieses eine Erfassung von bestehenden Theorien, Hypothesen und Verfahren vor, die für den Forschungsprozess relevant sind.⁵² Hierbei erfolgt ein Rückgriff auf Erkenntnisse aus den Formal- und empirischen Grundlagenwissenschaften. Anschließend werden unter Nutzung geeigneter Forschungsmethoden das Untersuchungsfeld im wissenschaftlichen und praxisbezogenen Kontext analysiert sowie damit verbundene Beobachtungen erklärt. Dazu wird zu Beginn das Untersuchungsfeld mittels eines konzeptionellen Rahmens beschrieben und abgegrenzt. Die Ergebnisse münden in der Ableitung der angesprochenen Gestaltungsempfehlungen für die Praxis, die mittels Rückkopplung mit entsprechenden Vertretern validiert und ggf. angepasst werden. Insgesamt ergibt sich so eine Verbindung von Theorieinhalten mit Informationen aus der Praxis an verschiedenen Stellen des Prozesses.

Die Beantwortung der Fragestellungen während des Forschungsprozesses werden durch das individuelle **Vorverständnis des Autors** beeinflusst, welches daher ebenfalls zu Beginn offenzulegen ist.⁵³ Im vorliegenden Fall ist dieses Verständnis maßgeblich durch eine fünfjährige wissenschaftliche Tätigkeit des Autors in zwei Forschungsprojekten und damit verbundenen Begleitaktivitäten am Fachgebiet Logistik der Technischen Universität Berlin geprägt. In den beiden Projekten namens SMECS⁵⁴ und SELECT⁵⁵ wurde jeweils eine ML-Anwendung für die Prognose und die darauf basierende Optimierung von spezifischen Logistikketten in Zusammenarbeit mit mehreren Unternehmen entwickelt. In diesem Zusammenhang fand ein intensiver Austausch mit nationalen und internationalen Vertretern aus Wirtschaft, Politik und Wissenschaft zum Einsatz von ML in der Logistik statt, was insgesamt zu einem multiperspektivischen Verständnis des Autors zum vorliegenden Untersuchungsfeld geführt hat.

⁵⁰ Vgl. Ulrich (1984), S. 184

⁵¹ Vgl. Ulrich (1984), S. 179

⁵² Vgl. hierzu und zu diesem Abschnitt Ulrich (1981), S. 19 ff.

⁵³ Vgl. Mayring (2002), S. 29 f.

⁵⁴ Das Projekt „Smart Event Forecast for Seaports“ wurde durch das Bundesministerium für Verkehr und digitale Infrastruktur von 2017 bis 2020 gefördert. Vgl. BMVI (2017)

⁵⁵ Das Projekt „Smarte Entscheidungsassistenten für Logistikketten der Binnenschifffahrt durch ETA-Prognosen“ wurde durch das Bundesministerium für Verkehr und digitale Infrastruktur von 2020 bis 2023 gefördert. Vgl. BMDV (2020)

1.4 Aufbau der Arbeit

Zur inhaltlichen Abgrenzung ist die vorliegende Arbeit in acht Kapitel unterteilt, die nachfolgend beschrieben und in Abbildung 4 mit ihren wesentlichen Inhalten, den adressierten Forschungsfragen sowie den korrespondierenden Phasen des gewählten Forschungsprozesses dargestellt sind.

Im Anschluss an das erste Kapitel, in dem die Problem- und Zielstellung sowie das Forschungsdesign und der Aufbau der Arbeit beschrieben werden, erfolgt im zweiten Kapitel eine Erarbeitung der theoretischen Grundlagen. Dies umfasst einleitend eine Einordnung der Arbeit in bestehende **Managementtheorien**. Anschließend wird das **Untersuchungsfeld** erschlossen und abgegrenzt, was sowohl die prozessuale Dimension in Form des Logistikmanagements als auch die technische Dimension in Form von ML und der übergeordneten Forschungsdisziplin KI betrifft. Im dritten Kapitel wird die **Forschungsmethodik** der Arbeit erläutert, wozu eine systematische Literaturanalyse, eine Clusteranalyse und eine empirische Untersuchung gehören. Letzteres setzt sich aus einer Gruppen- und Onlinebefragung sowie mehreren Interviews, einschließlich einer Fallstudienforschung, zusammen. Im vierten Kapitel findet eine Erfassung des **Status Quo und zukünftiger Entwicklungen** zum Untersuchungsfeld in der Praxis und Forschung statt. Im fünften Kapitel wird eine Typologie zu **Anwendungsmöglichkeiten** von ML im Logistikmanagement entwickelt und bewertet. Weiterhin werden die **Auswirkungen** von ML-Anwendungen in Form direkter Veränderungen, Nutzenpotenziale und Risiken erhoben. Im sechsten Kapitel werden die **Anforderungen** an den Technologieeinsatz im Logistikmanagement empirisch erfasst und bewertet. Auf Grundlage der erzielten Erkenntnisse werden im siebten Kapitel geeignete **Maßnahmen** zur erfolgreichen Gestaltung von ML-Anwendungen und deren Umfeld erarbeitet und in Form eines **Gestaltungsansatzes** systematisiert. Dieser wird abschließend anhand eines realen Anwendungsfalls validiert. Das achte Kapitel umfasst eine **Zusammenfassung** und kritische Würdigung der Ergebnisse, welche mit der Ausweisung weiterer Forschungsbedarfe abschließt.

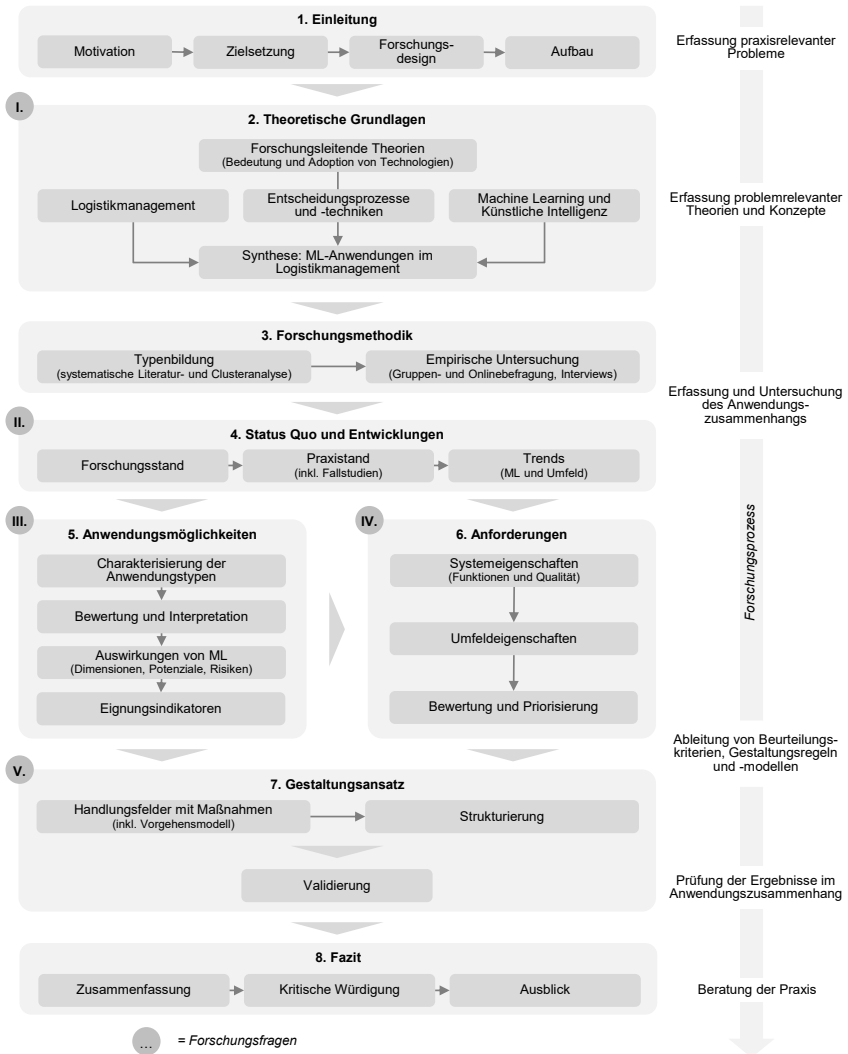


Abbildung 4: Aufbau und Forschungsprozess der Arbeit⁵⁶

⁵⁶ Eigene Darstellung

2 Theoretische Grundlagen

In diesem Kapitel werden die theoretischen Grundlagen für die Untersuchungen in der vorliegenden Arbeit erfasst. Dies beinhaltet eine Analyse bestehender Theorien, die in Hinblick auf das angestrebte Forschungsziel der Erklärung und Gestaltung diesbezüglicher Phänomene in der Praxis dienen. Zudem werden bedeutende Termini, Konzepte und Methoden der prozessualen und technischen Dimension des Untersuchungsfeldes ermittelt und systematisiert, was neben einer inhaltlichen Abgrenzung auch der Herausarbeitung von Referenzstrukturen für den weiteren Forschungsprozess dient. Insgesamt sollen die Aktivitäten des Kapitels zur Beantwortung der ersten sekundären Forschungsfrage führen:

Wie können ML-Anwendungen im Kontext des Logistikmanagements beschrieben und abgegrenzt werden? Welche wesentlichen Konzepte und Methoden sind hierbei zu berücksichtigen?

Ausgehend von einer Definition wichtiger technologischer Begriffe werden einleitend relevante **Forschungs- und Managementtheorien** analysiert und diesbezügliche Implikationen für die Arbeit abgeleitet (Kapitel 2.1). Anschließend werden das **Logistikmanagement**, damit verbundene Grundbegriffe und wesentliche logistische Prozesse erläutert (Kapitel 2.2). Nachfolgend findet eine theoretische Auseinandersetzung mit **Entscheidungsprozessen** im betrieblichen Kontext sowie mit den zur Unterstützung eingesetzten Techniken statt (Kapitel 2.3). Letzteres inkludiert eine Einordnung von ML und stellt damit den Übergang zur Betrachtung der technischen Dimension des Untersuchungsfeldes dar. Ausgehend von einer Darstellung des übergeordneten Forschungs- und Technologiebereiches in Form von **KI** werden hierbei die Möglichkeiten zur Realisierung einer systemseitigen Lernfähigkeit analysiert und gegenübergestellt, was zudem eine Definition von ML und der darauf basierenden **Lernenden Systeme** beinhaltet. Ebenfalls wird eine Systematisierung von ML anhand von Lerntypen, -aufgaben und -verfahren vorgenommen (Kapitel 2.4). Abschließend werden die Erkenntnisse zur modellhaften Abgrenzung der in der Arbeit betrachteten ML-Anwendungen im Logistikmanagement zusammengeführt (Kapitel 2.5).

Die Erfassung der Inhalte in diesem Kapitel erfolgt im Rahmen einer explorativ geprägten **Literaturanalyse**, deren Vorgehen sich an der Methode der konzentrischen Kreise (sog. Schneeballverfahren) orientiert, welche eine Ermittlung des Forschungsstands ausgehend von zentralen Veröffentlichungen vorsieht.⁵⁷ Die analysierten und eingebundenen Veröffentlichungen entstammen einem breiten Spektrum unterschiedlicher Disziplinen. In Bezug auf die forschungsleitenden Theorien umfasst dies Literatur zur strategischen Unternehmensführung sowie zum **Innovations- und Technologiemanagement**, einschließlich der Adoptionsforschung. Für die prozessuale Dimension werden Erkenntnisse aus der **Logistikforschung** genutzt. Die Veröffentlichungen zu KI und ML entstammen hauptsächlich der **Informatik**, wobei

⁵⁷ Vgl. Kornmeier (2007), S. 117 f.

auch Literatur aus der damit verbundenen Zukunftsforschung Eingang findet. Entsprechend des Zusammenhangs zur menschlichen Intelligenz wird in diesem Kontext auch Literatur der **Kognitionswissenschaften** eingebunden. Diese Disziplin findet ebenfalls im Rahmen der Betrachtungen zu Entscheidungsprozessen Berücksichtigung, wobei hier zusätzlich auf Erkenntnisse aus der deskriptiven⁵⁸ und präskriptiven⁵⁹ Entscheidungstheorie sowie dem assoziierten Teilbereich der **betriebswirtschaftlichen Entscheidungstheorie** zurückgegriffen wird, welcher die Untersuchung, Erklärung und methodische Unterstützung von Entscheidungen im Unternehmenskontext adressiert⁶⁰.

2.1 Forschungsleitende Theorien

In diesem Unterkapitel werden relevante Forschungs- und Managementtheorien analysiert und diesbezügliche Implikationen für die angestrebten Untersuchungen abgeleitet. Es handelt sich zum einen um Theorien, die einen Begründungszusammenhang zwischen der Wettbewerbsfähigkeit von Unternehmen und dem Technologieeinsatz herstellen. Zum anderen werden Theorien und darauf aufbauende Modelle zur Erklärung und erfolgreichen Gestaltung des Übernahmeprozesses von Technologien (Diffusion bzw. Adoption) betrachtet. Vorab werden bedeutende Begriffe im Technologiekontext definiert.

2.1.1 Technologische Grundbegriffe

Die Begriffe Technologie und Technik werden im deutschsprachigen Wissenschaftsdiskurs unterschiedlich verwendet.⁶¹ Eine Abgrenzungsmöglichkeit ergibt sich durch die systemorientierte Betrachtung beider Begriffe. Nach *Bullinger (1994)* bezeichnet **Technologie** das Wissen von interdisziplinären Zusammenhängen zur Lösung technischer Problemstellungen, wozu neben naturwissenschaftlichen und technischen auch betriebswirtschaftliche, soziale und politische Zusammenhänge zählen.⁶² Der **Technikbegriff** umfasst dagegen die Ergebnisse der Anwendung des Wissens in Form von Artefakten zur konkreten Problemlösung, wie Maschinen, Geräte oder Systeme. Nach diesem klassischen Verständnis wird Technologie als Ausgangsbasis (Input) für die Entwicklung von Technik (Output) interpretiert. Diese definitorische Abgrenzung ist jedoch bei realisierten Artefakten in der Praxis nicht immer eindeutig möglich, sodass sie u. a. im englischen Sprachraum auch nicht verfolgt wird. Vor diesem Hintergrund

⁵⁸ Die deskriptive Entscheidungstheorie setzt sich mit dem in der Realität stattfindenden Prozess von Entscheidungen auseinander. Auf dieser Grundlage werden empirische Zusammenhänge analysiert und erklärt, um Fehler bei der Entscheidungsfindung von Menschen und betrieblichen Organisationen zu identifizieren sowie Hypothesen zu deren zukünftigen Verhalten aufzustellen. Vgl. Bamberg et al. (2012), S. 5

⁵⁹ Im Kontext der präskriptiven Entscheidungstheorie werden Möglichkeiten zur Unterstützung zukünftiger Entscheidungen in der Realität erarbeitet. Ziel ist die Formulierung von Empfehlungen für das rationale Verhalten von Entscheidungsträgern durch die Bereitstellung von geeigneten Lösungstechniken. Vgl. Laux et al. (2018), S. 17; Kahle (2001), S. 24

⁶⁰ Vgl. Kahle (2001), S. 24; Bamberg et al. (2012), S. 11

⁶¹ Weiterführende Ausführungen siehe Binder, Kantowsky (1996), S. 87 ff.

⁶² Vgl. hierzu und zum folgenden Satz Bullinger (1994), S. 34 f.

wurde von *Binder, Kantowsky (1996)* ein **integratives Begriffsverständnis** eingeführt, welches Technik als Subsystem der Technologie versteht (siehe Abbildung 5). Nach diesem Verständnis – welches auch in der vorliegenden Arbeit Anwendung findet – ist Technologie wie folgt definiert:

„Technologie beinhaltet Wissen, Kenntnisse, Fähigkeiten und Fertigkeiten zur Lösung technischer Probleme, sowie die Anlagen, Einrichtungen und Verfahren, die dazu dienen, naturwissenschaftliche Erkenntnisse praktisch umzusetzen.“⁶³

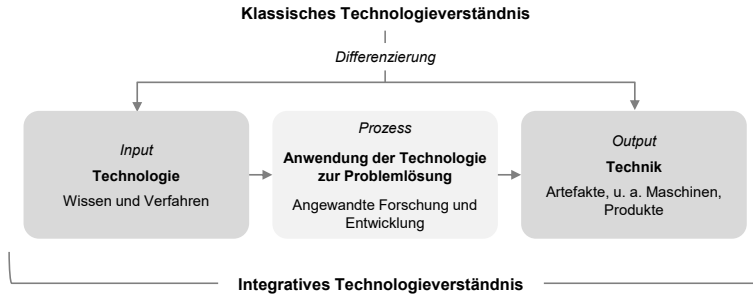


Abbildung 5: Systemorientiertes Begriffsverständnis von Technologien⁶⁴

Technologien, mit denen die Beschaffung, Verarbeitung, Übertragung, Speicherung und/oder Bereitstellung von Informationen erfolgt, werden als Informationstechnologien oder – im Sinne des Technikbegriffes – als **Informationssysteme (IS)** bezeichnet.⁶⁵ IS weisen neben maschinellen auch menschliche Komponenten in Form der jeweiligen Nutzer und Entwickler auf, welche durch Kommunikationsbeziehungen miteinander verbunden sind, sodass aus systemtheoretischer Sicht von soziotechnischen Systemen gesprochen wird.⁶⁶ Die maschinelle Komponente wird durch ein **Anwendungssystem** repräsentiert, welches sowohl aus Software- als auch aus Hardwarebestandteilen besteht. Software kann nach der *ISO/IEC 2382:2015* wiederum in Anwendungs-, System- und Unterstützungssoftware unterschieden werden, wobei **Anwendungssoftware**⁶⁷ im Gegensatz zu den anderen Ausprägungen stets für die Lösung spezifischer Anwenderprobleme oder -aufgaben entwickelt wird.⁶⁸ Die Gesamtheit der Anwendungssoftware, die zusammen mit weiteren Software- und Hardwarebestandteilen für ein konkretes betrieblichen Anwendungsgebiet eingesetzt wird, bildet ein Anwendungssystem.⁶⁹ Aus dem stets vorliegenden Bezug zu einer spezifischen betrieblichen Aufgabe bzw. Problemlösung leitet sich die dritte Komponente eines IS ab. Insgesamt ergibt sich der in Abbildung 6

⁶³ Binder, Kantowsky (1996), S. 91

⁶⁴ Eigene Darstellung in Anlehnung an Binder, Kantowsky (1996), S. 92; Bullinger (1994), S. 34

⁶⁵ Vgl. Schwarze (2000), S. 46

⁶⁶ Vgl. Hansen et al. (2019), S. 12 f.

⁶⁷ Der Begriff der Anwendungssoftware wird im weiteren Verlauf häufig in der Kurzform der Software genutzt.

⁶⁸ Vgl. Leimeister (2015), S. 66

⁶⁹ Vgl. Stahlknecht, Hasenkamp (2002), S. 208

dargestellte modellhafte Aufbau dieser Systeme, welcher aus den drei Komponenten Anwendungssystem, Mensch und Aufgabe besteht, die aus systemtechnischer Sicht auch als **Subsysteme** der IS bezeichnet werden.⁷⁰

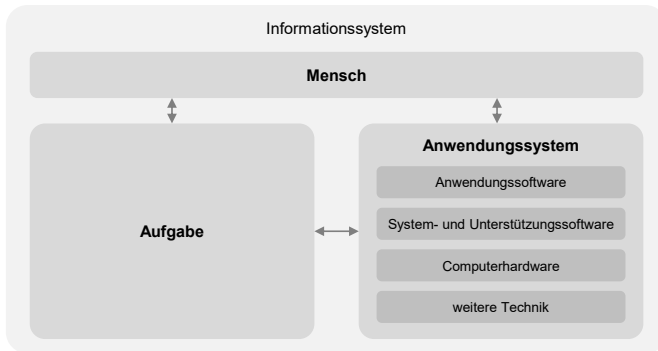


Abbildung 6: Systemtechnisches Modell vom Informationssystemen⁷¹

Handelt es sich bei den betrachteten Technologien um Neuerungen, wird von technischen Innovationen bzw. – unter Berücksichtigung des integrativen Begriffsverständnisses – von **technologischen Innovationen** gesprochen.⁷² Innovationen sind wiederum Ideen, Prozesse oder Objekte, die von einem Individuum oder einer übergeordneten Einheit, z. B. einem Unternehmen, als neu wahrgenommen werden.⁷³ Bedeutende informationstechnische Neuerungen werden als **IT-Innovationen** bezeichnet. Für technologische Innovation, die einen wesentlichen Beitrag zur digitalen Transformation leisten, wie es bereits einleitend in der vorliegenden Arbeit für Machine Learning festgestellt wurde, findet zudem der Begriff der **digitalen Technologien** Anwendung.

2.1.2 Strategische Bedeutung von Technologien

Für die Sicherstellung der Wettbewerbsfähigkeit von Unternehmen bedarf es einer kontinuierlichen Identifikation von Möglichkeiten zum Aufbau und zum nachhaltigen Aufrechterhalten von Wettbewerbsvorteilen.⁷⁴ Zum potenziellen Lösungsraum gehört auch der Einsatz von technologischen Innovationen.⁷⁵ Für die Erklärung der Bedeutung von Technologien zur **Generierung von Wettbewerbsvorteilen** haben sich verschiedene theoretische Ansätze herausgebildet, die teilweise aufeinander aufbauen. Im Folgenden werden diejenigen Theorien mit der höchsten Relevanz für die vorliegende Arbeit dargestellt. Dabei handelt es sich um den Market-based View (MBV), den Resource-based View (RBV), den Competence-based View

⁷⁰ Vgl. Hansen et al. (2019), S. 15

⁷¹ Eigene Darstellung

⁷² Vgl. Bullinger (1994), S. 35

⁷³ Vgl. Rogers (1983), S. 11

⁷⁴ Vgl. Teece et al. (1997), S. 510

⁷⁵ Vgl. Bullinger (1994), S. 39

(CBV) und den Dynamic Capabilities View (DCV). Deren zentrale Aussagen und Beziehungen finden sich vorab in Abbildung 7.

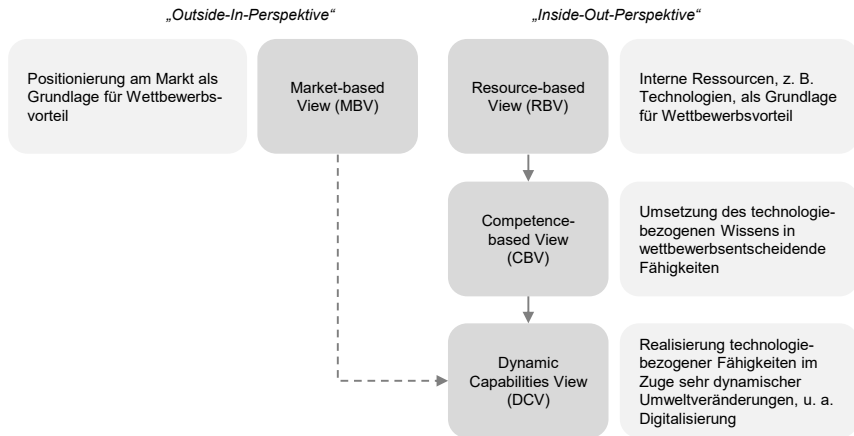


Abbildung 7: Theorien zur Erklärung der strategischen Bedeutung von Technologien⁷⁶

2.1.2.1 Market-based View

Der marktorientierte Ansatz macht den Erfolg von Unternehmen im Wesentlichen von der Positionierung gegenüber Wettbewerbern abhängig.⁷⁷ Als wichtiger Vertreter dieses Ansatzes gilt *Porter (1998)*, der in den 1980er Jahren verschiedene Branchenstrukturen und darauf basierende generische Wettbewerbsstrategien von Unternehmen untersucht hat. In Abhängigkeit der gegebenen Wettbewerbssituation können im Kontext des MBV Chancen und Risiken für Unternehmen entstehen, die bei deren strategischer Gestaltung zu berücksichtigen sind. Dementsprechend vertritt dieser Ansatz eine extern orientierte Sicht (sog. **Outside-In-Perspektive**), nach der sich Unternehmen entsprechend des Marktumfeldes für die Erzielung eines Wettbewerbsvorteils anpassen müssen.⁷⁸ Technologien werden im Kontext des MBV ebenfalls betrachtet, indem damit verbundene Innovationen zu strategischen Vorteilen führen können, wobei dies häufig für den gesamten Markt zutrifft.⁷⁹ Einen Erklärungsansatz für einen technologiebasierten Wettbewerbsvorteil von Unternehmen bietet der MBV jedoch weniger. Allerdings vermittelt er die Bedeutung zur Analyse von externen Veränderungen – welche u. a. auf neue Technologien zurückgehen können.

⁷⁶ Eigene Darstellung

⁷⁷ Vgl. Teece et al. (1997), S. 511

⁷⁸ Vgl. Barney (1991), S. 99 f.

⁷⁹ Vgl. Porter (1998), S. 229

2.1.2.2 Resource-based View

Basierend auf den Untersuchungen von *Penrose (1997)* entstanden als Reaktion auf den MBV seit Ende der 1980er Jahre mehrere Theorien⁸⁰, die einen ressourcenorientierten Ansatz verfolgen.⁸¹ Der RBV postuliert, dass Wettbewerbsvorteile nicht alleine auf die Marktposition von Unternehmen, sondern auch auf interne Gegebenheiten der Unternehmen zurückzuführen sind. Insbesondere in Märkten mit schnellen technologischen Änderungen können unternehmensinterne Ressourcen einen höheren Beitrag zum Unternehmenserfolg leisten, als es im Rahmen des MBV angenommen wird.⁸² Anstatt des externen Fokus nimmt der RBV daher eine interne Betrachtung von Unternehmen ein (sog. **Inside-out-Perspektive**).⁸³ Aus Sicht des RBV bestehen Unternehmen aus einem Bündel von spezifischen Ressourcen, welche die Grundlage für deren Erfolg oder Misserfolg bilden.⁸⁴ Ressourcen sind sämtliche materielle und immaterielle Assets, über die ein Unternehmen zur Verbesserung seiner Effektivität und Effizienz verfügen kann, d. h. alle Vermögenswerte, Fähigkeiten, Prozesse, Unternehmensmerkmale und Informationen.⁸⁵ Der RBV führt Erfolgsunterschiede von Unternehmen innerhalb einer Branche auf eine heterogene Ausstattung mit diesen Ressourcen⁸⁶ zurück. Wettbewerbsvorteile können daher nur durch deren gezielten Aufbau umgesetzt werden.⁸⁷ Neben Technologien, wie Maschinen und IT-Systeme, versteht der RBV auch die Fähigkeiten zur Technologienutzung in Form von Wissen, Strukturen und Prozessen als Ressourcen.⁸⁸ Zur Erzielung von Wettbewerbsvorteilen müssen Unternehmen daher in der Lage sein, neue erfolgskritische Technologien zu identifizieren, sich anzueignen und diese umzusetzen.⁸⁹

2.1.2.3 Competence-based View

Der kompetenzorientierte Ansatz wurde zu Beginn der 1990er Jahre als Präzisierung des RBV von *Prahalad, Hamel (2006)* begründet.⁹⁰ Er folgt der Annahme, dass die bloße Ausstattung mit Ressourcen für eine Erklärung von Wettbewerbsvorteilen nicht ausreichend ist. Vielmehr bedarf es besonderer Kompetenzen der Unternehmen, um die Ressourcen zielgerichtet entsprechend der jeweiligen Anforderungen des Marktes einzusetzen.⁹¹ Erst durch die **ressourcenbezogenen Kompetenzen** sind Unternehmen in der Lage, das vom RBV postulierte Potenzial von Ressourcen im Sinne eines effektiveren und effizienteren Einsatzes im Vergleich

⁸⁰ Vgl. Priem, Butler (2001), S. 24

⁸¹ Vgl. Sanchez, Heene (1997), S. 305

⁸² Vgl. Teece et al. (1997), S. 511

⁸³ Vgl. Barney (1991), S. 100

⁸⁴ Vgl. Wernerfelt (1984), S. 172

⁸⁵ Vgl. Barney (1991), S. 101

⁸⁶ Nach dem sog. VRIO-Schema müssen erfolgswirksame Ressourcen einen Nutzen für den Kunden haben (Value) sowie nicht-substituierbar (Rarity), nicht-imitierbar (Inimitability) und unternehmensspezifisch (Organisational specificity) sein. Vgl. Barney (1991), S. 105 f.

⁸⁷ Vgl. Barney (2001), S. 648 f.

⁸⁸ Vgl. Wernerfelt (1984), S. 172

⁸⁹ Vgl. Schulte-Gehrmann et al. (2011), S. 58

⁹⁰ Vgl. Sanchez, Heene (1997), S. 305 f.

⁹¹ Vgl. Freiling (2004), S. 31

zu Wettbewerbern zu erschließen. Als wettbewerbsrelevante Kompetenzen⁹² werden Fähigkeiten eines Unternehmens zur Erschließung derjenigen Technologien und Produktionsfertigkeiten bezeichnet, die eine schnelle Reaktion auf veränderte Umweltbedingungen ermöglichen.⁹³ Ihr Aufbau und Einsatz muss durch die Unternehmensführung gezielt koordiniert werden: Es können entweder bestehende Kompetenzen weiterentwickelt (sog. Competence Leveraging) oder neue Kompetenzen erworben werden (sog. Competence Building).⁹⁴ Für die Herausbildung von Kompetenzen sind im Sinne des CBV auch Kooperationen mit Partnern im Netzwerk zu prüfen, um schnell auf Marktchancen reagieren zu können.⁹⁵

2.1.2.4 Dynamic Capabilities View

Der Ansatz der dynamischen Fähigkeiten von Unternehmen wurde Ende der 1990er Jahre von Teece et al. (1997) als eine Ergänzung des RBV und CBV begründet.⁹⁶ Er entstand als Reaktion auf eine stärkere Frequenz von größeren wettbewerbsbezogenen, technischen, gesellschaftlichen und regulatorischen Veränderungen, mit denen Unternehmen konfrontiert sind und die zur Anpassung der eigenen Ressourcen und Fähigkeiten genutzt werden können.⁹⁷ Anders als die bisherigen Ansätze liefert der DCV ein theoretisches Fundament für den Umgang mit diesen schnellen Veränderungen zur Erzielung langfristiger Wettbewerbsvorteile.⁹⁸ Demnach müssen Unternehmen sog. **dynamische Fähigkeiten** entwickeln, die nach Teece et al. (1997) wie folgt definiert sind: „*The firm's ability to integrate, build and reconfigure internal and external competencies to address rapidly changing environments.*“⁹⁹ Bei den erforderlichen Fähigkeiten wird allgemein in folgende Ausprägungen unterschieden:

- Sensing: Die Fähigkeit, Chancen und Bedrohungen aus Veränderungen in der Umwelt zu erkennen.
- Seizing: Die Fähigkeit, Ressourcen zu mobilisieren, um Vorteile aus den identifizierten Chancen zu ziehen.
- Transformation: Die Fähigkeit, Ressourcen fortwährend zu verbessern, neu zu kombinieren oder zu modifizieren, um Wettbewerbsvorteile aufrecht zu erhalten.¹⁰⁰

Mithilfe diesbezüglicher Fähigkeiten soll sichergestellt werden, dass über die Nutzung von einmal – im Sinne des RBV und CBV – erkannten Chancen eine kontinuierliche Weiterentwicklung der Unternehmen im Einklang mit Umweltveränderungen erfolgt, um den initialen Wettbewerbsvorteil nachhaltig aufrechtzuerhalten.¹⁰¹ Hierbei wird von einem organisationalen

⁹² Auch bei den Kompetenzen muss es sich um einzigartige Ausprägungen im Sinne des VRIO-Schemas handeln.

⁹³ Vgl. Prahalad, Hamel (2006), S. 277

⁹⁴ Vgl. Sanchez, Heene (1997), S. 306

⁹⁵ Vgl. Sanchez, Heene (1997), S. 314

⁹⁶ Vgl. Barreto (2010), S. 259

⁹⁷ Vgl. Teece (2007), S. 1320

⁹⁸ Vgl. Barreto (2010), S. 259

⁹⁹ Teece et al. (1997), S. 512

¹⁰⁰ Vgl. Teece (2007), S. 1319; Barreto (2010), S. 272

¹⁰¹ Vgl. Teece (2007), S. 1347

Lernprozess ausgegangen, bei dem die zukünftige Entwicklung von Unternehmen von den bestehenden Voraussetzungen abhängig ist.¹⁰² Auch im Sinne des DCV wird die Entwicklung der Fähigkeiten mit einer gezielten Übernahme von neuen Technologien assoziiert, wobei anstelle eines externen Zukaufes dem eigenen Aufbau der damit verbundenen Fähigkeiten eine höhere Erfolgswirksamkeit beigemessen wird.¹⁰³

2.1.3 Adoption von Technologien

Die zuvor genannten Theorien verdeutlichen die strategische Bedeutung von Technologien. Sie zeigen aber auch, dass Unternehmen für jede Technologie individuelle Maßnahmen zu deren potenziellen Einsatz entsprechend der internen und externen Rahmenbedingungen ergreifen müssen. Dies betrifft eine vorgelagerte **Entscheidung** zu der Übernahme oder Ablehnung der jeweiligen Technologie sowie eine anschließende **Gestaltung des Übernahmeprozesses** in die Organisation zur Realisierung von Wettbewerbsvorteilen. Die Erklärung dieser Aktivitäten erfolgt im Rahmen der Diffusionstheorie (Diffusion of Innovations, DOI), welche ausgehend von einer innovationsübergreifenden Betrachtung die Grundlage für weitere theoretische Ansätze zur Fokussierung von bestimmten Innovationen und/oder von Teilaspekten des Übernahmeprozesses darstellt.

Für die vorliegende Arbeit wurden neben der DOI spezielle Theorien zur Erklärung und Gestaltung des Einsatzes von technologischen Innovationen bzw. von Informationssystemen ausgewählt. Dazu gehören das Technology-Organization-Environment-Modell (TOE) sowie das Mensch-Technik-Organisation-Konzept (MTO), welche den Übernahmeprozess auf **gesamtorganisatorischer Ebene** adressieren. Zusätzlich wird das Technology-to-Performance-Chain-Modell (TPC) herangezogen, welches diese Untersuchungen auf einer **anwendungsbezogenen Ebene** in Hinblick auf individuelle Anwendungsfälle und Nutzungsvoraussetzungen theoretisch fundiert. Die zentralen Aussagen und Beziehungen dieser Theorien finden sich in Abbildung 7 und werden nachfolgend beschrieben.

¹⁰² Vgl. Teece (2007), S. 1325

¹⁰³ Vgl. Barreto (2010), S. 259

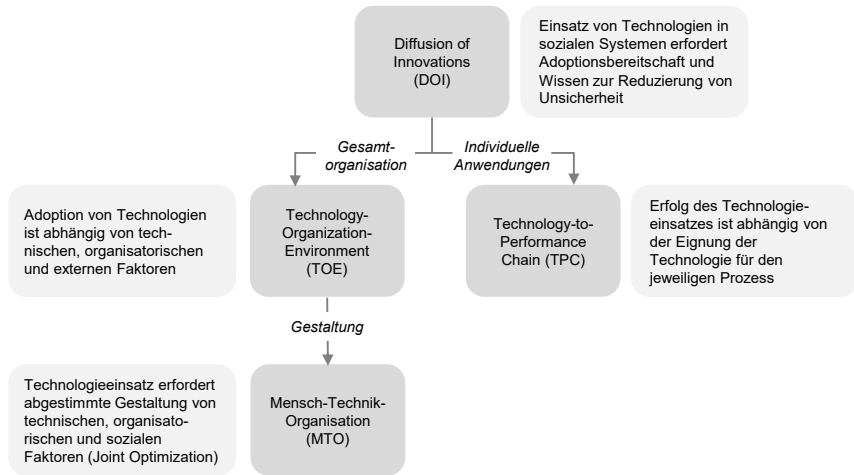


Abbildung 8: Theorien zur Gestaltung der Adoption von Technologien¹⁰⁴

2.1.3.1 Diffusion of Innovations

In Hinblick auf eine gesamtunternehmerische Zielsetzung soll der Einsatz von technologischen Innovationen bei der Lösung von betrieblichen Problemen unterstützen.¹⁰⁵ Dies setzt eine vorausgehende Integration der Technologie in die jeweilige Organisation voraus. Zur Erklärung von Zusammenhängen bei der Übernahme von Innovationen in einem sozialen System in Form eines Unternehmens oder einer gesamten Branche wurde die Diffusionstheorie in den 1960er Jahren durch *Rogers (1983)* begründet. Die **Diffusion** beschreibt den Prozess der Ausbreitung einer Innovation unter den Mitgliedern des sozialen Systems im Zeitverlauf.¹⁰⁶ Im Falle der Betrachtung des Übernahmeprozesses in Bezug auf diese einzelnen Mitglieder wird wiederum von einer **Adoption** gesprochen, wobei die Mitglieder als Adoptionssubjekte bezeichnet werden.¹⁰⁷ Demzufolge entspricht die Diffusion einer kumulierten Betrachtung dieser Individualebene, was auch zu einer engen Verbindung zwischen der Diffusion- und der Adaptionstheorie führt.

Eine erfolgreiche Diffusion hängt von den Individualentscheidungen der einzelnen Organisationsmitglieder über deren Annahme oder Ablehnung der jeweilige Innovation ab.¹⁰⁸ Diese Entscheidungen sind von einer hohen Unsicherheit über den tatsächlichen Beitrag der Innovation zur Problemlösung sowie damit verbundener positiver und negativer Auswirkungen geprägt.¹⁰⁹ Mit dem Ziel der Reduzierung dieser Unsicherheit werden in der Regel mehrere Aktivitäten zur

¹⁰⁴ Eigene Darstellung

¹⁰⁵ Vgl. *Rogers (1983)*, S. 6

¹⁰⁶ Vgl. *Rogers (1983)*, S. 5

¹⁰⁷ Vgl. *Gerpott (1999)*, S. 121, 126

¹⁰⁸ Vgl. *Rogers (1983)*, S. 21

¹⁰⁹ Vgl. hierzu und zum folgenden Satz *Rogers (1983)*, S. 13

Informationssuche und -verarbeitung durch die Mitglieder bzw. das Unternehmen durchgeführt, die von *Rogers (1983)* im Rahmen des sog. Innovationsentscheidungsprozesses systematisiert wurden. Die fünf Phasen dieses idealtypischen Prozesses, der häufig auch als **Adoptionsprozess** bezeichnet wird, sind in Abbildung 9 dargestellt und werden im Folgenden anhand einer technologischen Innovation beschrieben.




Abbildung 9: Adoptionsprozess¹¹⁰

Zu Beginn des Adoptionsprozesses steht der Bedarf zur Lösung eines Problems, wobei dieses sowohl zeitlich vor der Kenntnis über die Innovation bekannt sein als auch erst nach der Kenntnis über die Innovation und ihre Möglichkeiten sichtbar werden kann.¹¹¹ In der Wissensphase erfährt ein potenzieller Adopter von der Technologie und entwickelt dazu ein Verständnis, ohne dass er bereits eine Bewertung trifft. Es handelt sich oftmals um eine aktive Suche nach Informationen, mit denen der Adopter seine Unsicherheit über die Technologie und deren Fähigkeit zum Einsatz für die Lösung betrieblicher Probleme verringern möchte. Bei dem gewonnenen Wissen kann es sich um Informationen zur bloßen Existenz der Technologie (Awareness-Knowledge) sowie um Anwendungsmöglichkeiten (How-to-Knowledge) und um Grundlagenwissen (Principles-Knowledge) handeln. In der Überzeugungsphase (Persuasion Stage) ermittelt der Adopter die Vor- und Nachteile der Technologie, wodurch eine erste Bewertung möglich ist. Häufig wird zur Verringerung der Unsicherheit zusätzlich eine Erprobung der Technologie, z. B. in Form von Prototypen, durchgeführt. Das bisherige Wissen mündet im Rahmen der Entscheidungsphase in einer Entscheidung für eine Adoption oder Ablehnung der Technologie. Im erstgenannten Fall erfolgen in der Umsetzungsphase eine Einführung und Anwendung der Technologie, wobei es zu iterativen Anpassungen kommen kann. In der abschließenden Bestätigungsphase werden die erzielten Erfahrungen mit den vorherigen Annahmen zu Vor- und Nachteilen abgeglichen und der Erfolg bewertet, was in einer nachträglichen Bestätigung oder Ablehnung mündet. Im Falle einer Bestätigung erfolgt eine weiterführende Integration der Technologie in die Unternehmensstrukturen.

Die Entscheidungen innerhalb des Adoptionsprozesses, welche auf Individualebene zur Annahme oder Ablehnung führen und damit aus übergeordneter Sicht den Erfolg oder Misserfolg eines Technologieeinsatzes bestimmen, werden durch verschiedene Faktoren beeinflusst.¹¹² Neben der grundsätzlichen Adoptionsbereitschaft determinieren diese **Einfluss- oder Adoptionsfaktoren**¹¹³ auch die Geschwindigkeit eines Adoptionsprozesses, d. h. die Anzahl von Teilnehmern eines Systems, welche innerhalb eines Zeitraums die Technologie übernehmen

¹¹⁰ Eigene Darstellung in Anlehnung an *Rogers (1983)*, S. 165

¹¹¹ Vgl. hierzu und zu diesem Abschnitt *Rogers (1983)*, S. 21, 164 ff.

¹¹² Vgl. *Rogers (1983)*, S. 11

¹¹³ Die Einflussfaktoren werden im Kontext zukünftiger Adoptionen von Technologien auch als Prädiktoren (Predictors) bezeichnet. Vgl. *Baker (2012)*, S. 237; *Rogers (1983)*, S. 358

(sog. Adoptionsrate bzw. Diffusionskurve).¹¹⁴ Rogers (1983) führt in diesem Zusammenhang mehrere Faktoren auf, die sich insbesondere auf Merkmale der Innovation beziehen, z. B. deren relativer Vorteil gegenüber anderen Innovationen, deren Kompatibilität zu den Erfahrungen, Bedarfen und geltenden Werten des jeweiligen Systems, deren Verständlichkeit und Anwendbarkeit sowie die Sichtbarkeit von deren zentralen Eigenschaften und positiven Auswirkungen.¹¹⁵

2.1.3.2 Technology-Organization-Environment

Aufbauend auf der DOI-Theorie wurde mit dem **TOE-Modell** von DePietro et al. (1990) ein spezialisiertes Modell für die Adoption von *technologischen* Innovationen begründet. In Ergänzung zu den Erkenntnissen von Rogers (1983) liefert diese Theorie einen Erklärungsansatz für relevante Faktoren, welche die Adoption beeinflussen und daher bei der Entscheidung zum Technologieeinsatz von Unternehmen zu berücksichtigen sind.¹¹⁶ Hierzu wurde eine Systematisierung der interdisziplinären Faktoren vorgenommen, wobei auch eine separate Dimension zu Faktoren aus dem Umfeld von Unternehmen (External Task Environment) berücksichtigt wurde (in Abbildung 10).

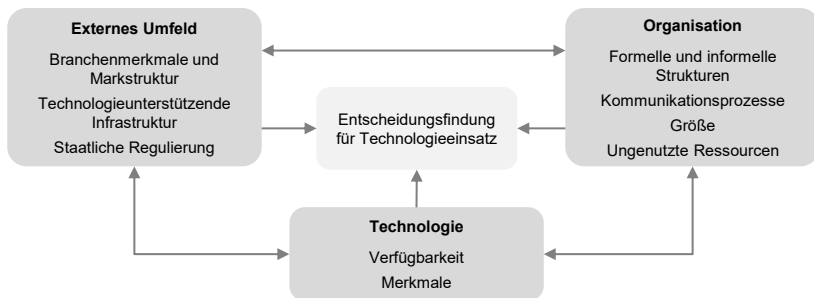


Abbildung 10: TOE-Modell¹¹⁷

Die **technologische Dimension** des TOE-Modells bezieht sich zum einen auf die Eigenschaften der betrachteten Technologie, welche individuell für das jeweilige Adoptionsobjekt zu ermitteln sind.¹¹⁸ Zum anderen sind auch alle bereits verfügbaren Technologien des jeweiligen Unternehmens zu berücksichtigen, da sich hieraus dessen Fortschritt und Wandlungsfähigkeit sowie Ansatzpunkte zur technischen Weiterentwicklung ableiten lassen. In diesem Kontext sollte auch das bestehende Wissen des Unternehmens zur Anwendung der betreffenden Technologie betrachtet werden.

¹¹⁴ Vgl. Rogers (1983), S. 232; Gerpott (1999), S. 123 f.

¹¹⁵ Vgl. Rogers (1983), S. 211

¹¹⁶ Das Modell ist in Tornatzky, Fleischer (1990) erschienen und wird häufig in der Literatur mit diesen beiden Autoren assoziiert.

¹¹⁷ Eigene Darstellung in Anlehnung an DePietro et al. (1990), S. 153

¹¹⁸ Vgl. hierzu und zu diesem Abschnitt DePietro et al. (1990), S. 163 ff.

Die **organisationale Dimension** sollte verschiedene Merkmale des Unternehmens abdecken, wozu formelle und informelle Organisationsstrukturen gehören, welche z. B. den Informations- und Ideenaustausch oder die abteilungsübergreifende Unterstützung einer Adoption beeinflussen.¹¹⁹ Ferner sind auch betriebliche Kommunikationsprozesse zu betrachten, wozu die aktive „Vermarktung“ und Förderung einer geplanten Technologieeinführung durch die Unternehmensführung zählen. Diese werden wiederum von der grundsätzlichen Einstellung und dem Verhalten der Führungskräfte gegenüber Veränderungen beeinflusst, sodass auch diese Faktoren Berücksichtigung finden sollten. Zusätzlich ist auch die Größe des Unternehmens zu betrachten, welche jedoch nicht nur anhand der Mitarbeiteranzahl, sondern auch am Umsatz und Gewinn des Unternehmens zu bestimmen ist. Ein weiteres Merkmal stellen die für die Adoption zur Verfügung stehenden finanziellen und personellen Ressourcen dar.

Zur zusätzlichen **externen Dimension** gehören z. B. die Eigenschaften und Struktur der Branche des jeweiligen Unternehmens, welche einen Hinweis auf die Adoptionsbereitschaft der dort agierenden Unternehmen geben können, da es sich bspw. um eine Branche mit einem schnellen Wachstum oder Rückgang handelt.¹²⁰ Auch die Verfügbarkeit externer Ressourcen in Form von unterstützenden Lieferanten und Dienstleistern sowie Arbeitskräften und Begleittechnologien ist relevant. Zudem ist das regulatorische Umfeld zu berücksichtigen, von dem u. a. adoptionsfördernde finanzielle Anreize, aber auch hemmende Restriktionen, z. B. gesetzliche Vorgaben, ausgehen können.

Die bisherigen Forschungsarbeiten zeigen eine vielfältige Anwendbarkeit und einen hohen Erklärungshalt des TOE-Modells in Bezug auf die Adoption von verschiedenen Technologien in unterschiedlichen Branchen.¹²¹ Insbesondere für Anwendungssysteme – auch im Kontext der Logistik – existiert eine Vielzahl von Untersuchungen.¹²² Aus den Veröffentlichungen wird auch ersichtlich, dass die relevanten Einflussfaktoren innerhalb der drei Dimensionen des TOE-Modells in Abhängigkeit des Untersuchungsfeldes stark variieren. Ausgehend von diesen empirischen Erkenntnissen leitet *Baker (2012)* die Notwendigkeit ab, dass für jede Technologie und jeden Anwendungsbereich eine **spezifische Untersuchung von Einflussfaktoren** erfolgen muss: „[...] *that for each specific technology or context that is being studied, there is a unique set of factors to measure.*“¹²³

2.1.3.3 Mensch-Technik-Organisation

Mit dem MTO-Konzept wurde Ende der 1990er Jahre von *Strohm, Ulich (1997)* ein theoretischer Ansatz zur Analyse und Bewertung von Unternehmen in Hinblick auf die Einführung von Technologien entwickelt. Anders als die bisher vorgestellten Theorien, welche primär einer Erklärung von Adoptionsprozessen dienen, adressiert das MTO-Konzept deren Gestaltung,

¹¹⁹ Vgl. hierzu und zu diesem Abschnitt DePietro et al. (1990), S. 154 ff.

¹²⁰ Vgl. hierzu und zu diesem Abschnitt DePietro et al. (1990), S. 166 ff.

¹²¹ Vgl. Baker (2012), S. 235

¹²² Übersichten finden sich in Oliveira, Martins (2011), S. 113 ff.; Baker (2012), S. 235 ff.

¹²³ Baker (2012), S. 236.

indem es verschiedene Bereiche vorgibt, die bei der Gestaltung eines erfolgreichen Technologieeinsatzes zu berücksichtigen sind. Aus dem Verständnis von Unternehmen als soziotechnische Systeme geht das MTO-Konzept dabei analog zum TOE-Modell über eine isolierte Betrachtung der jeweiligen Technologie hinaus, indem es eine **abgestimmte Gestaltung** von technologischen, organisatorischen und sozialen Faktoren (sog. Joint Optimization) fordert.¹²⁴ Aufgrund von starken Abhängigkeiten und Wechselwirkungen zwischen diesen drei Dimensionen wird zusätzlich betont, dass die einzelnen Schnittstellen bei der Gestaltung im besonderen Maße zu betrachten sind. Zusätzlich wird auf die **Einbettung der Unternehmen in ein Umfeld** hingewiesen, welches u. a. durch gesellschaftliche, politische und wirtschaftliche Faktoren determiniert wird und daher ebenfalls bei der Gestaltung des Technologieeinsatzes zu berücksichtigen ist.

Anwendung findet das MTO-Konzept in der Forschung zur Gestaltung der digitalen Transformation von Unternehmen, wobei die entsprechenden Arbeiten jeweils eine technologieübergreifende Untersuchung vorgenommen haben.¹²⁵ Hierbei wird stets auf die Bedeutung der integrativen Berücksichtigung verschiedener Gestaltungsdimensionen bei **digitalen Technologien** hingewiesen, da deren Einführung mit größeren Transformationsprozessen verbunden ist, die über technologische Veränderungen hinausgehen. Entgegen dieser Notwendigkeit wurde für die Logistik festgestellt, dass sich die bisherigen Maßnahmen in Unternehmen v. a. auf die technologische Gestaltungsdimension beschränken und personelle bzw. organisatorische Aspekte vernachlässigt werden.¹²⁶

2.1.3.4 Technology-to-Performance Chain

Gemäß der DOI-Theorie wird der Technologieerfolg durch die Adoptionsbereitschaft einzelner Organisationsmitglieder beeinflusst. Die beiden vorausgegangenen Theorien haben entsprechend ihrer gesamtorganisatorischen Sicht diese Individualebene jedoch nur partiell in Form einzelner Einflussfaktoren berücksichtigt, sodass diese Betrachtungen als weiterer Forschungsbedarf ausgewiesen werden.¹²⁷ Eine detaillierte Erklärung der Phänomene auf dieser Ebene erfolgt dagegen durch theoretische Ansätze der **Akzeptanzforschung**, welche die subjektive Einstellung von bestehenden und potenziellen Nutzern gegenüber Innovationen untersuchen. Bedeutende Vertreter in diesem Kontext sind das Technology-Acceptance-Model 1 und 2, welche auf *Davis (1989)* bzw. *Venkatesh, Davis (2000)* zurückgehen und u. a. personenbezogene Merkmale der Nutzer analysieren. Diese sozialpsychologische Perspektive wird im **TPC-Modell** um eine Betrachtung des Problembezugs von Innovationen erweitert. Demnach stellt das von *Goodhue, Thompson (1995)* speziell für Informationssysteme begründete Modell sowohl in Bezug auf deren Verwendung durch die Nutzer als auch hinsichtlich deren

¹²⁴ Vgl. hierzu und zu diesem Abschnitt Ulich (2013), S. 5 f.

¹²⁵ Vertreter sind u. a. Hirsch-Kreinsen, Ittermann (2021); See, Kersten (2017); Dregger et al. (2016).

¹²⁶ Vgl. See, Kersten (2018), S. 9

¹²⁷ Vgl. Baker (2012), S. 242

Eignung für die jeweils angedachte Problemstellung einen Zusammenhang zur Adoptionsbereitschaft her (siehe Abbildung 11).

Die problembezogene Eignung wird beim TPC-Modell durch den sog. **Task-Technology-Fit (TTF)** erfasst, der den Erfüllungsgrad der jeweiligen Technologie in Bezug auf die Unterstützung der intendierten Aufgaben angibt.¹²⁸ Zur Bestimmung des TTF müssen sowohl die Eigenschaften der Technologie als auch der adressierten Aufgaben **kontextbezogen anhand geeigneter Merkmale** erhoben und zu Funktionalitäten der Technologie synthetisiert werden. Anschließend findet eine Prüfung der Funktionalitäten in Hinblick auf die resultierende Leistung (Performance) statt, welche anhand festgelegter Ziele für den Technologieeinsatz beurteilt wird, z. B. in Form einer verbesserten Effizienz, Effektivität und Qualität. Im Falle eines höheren TTF wird auch eine höhere Leistung der Technologie erwartet, welche wiederum zu einer höheren Adoptionsbereitschaft führt. Die angesprochene Betrachtung der Verwendung der Technologie durch die Nutzer (Utilization) findet innerhalb einer separaten Dimension im TPC-Modell statt. Zu deren Bewertung werden mehrere Faktoren benannt, die sich auf die **individuelle Einstellung** und Rahmenbedingungen der Nutzer beziehen, u. a. die erwarteten Folgen der Nutzung, das damit verbundene Gefühl, soziale Normen sowie die Verfügbarkeit von zeitlichen, finanziellen und technischen Ressourcen für die Technologieeinführung.

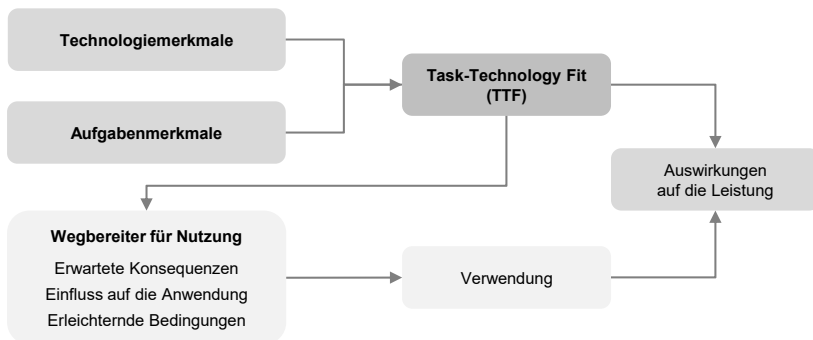


Abbildung 11: TPC-Modell¹²⁹

Die bestehenden Forschungsarbeiten auf Grundlage des TPC-Modells adressieren verschiedene Informationssysteme und Anwendungsbereiche, wobei analog zum TOE eine individuelle Ermittlung der einzelnen Merkmale zu beobachten ist. Weiterhin wird festgestellt, dass die Prüfungsschritte des Modells sowohl qualitativ als auch quantitativ durchgeführt werden können, wobei Letzteres eher im Fall von bereits umgesetzten Technologien stattfindet. Entsprechend der Modelllogik ist der TTF nicht abhängig von der Nutzung der jeweiligen Technologie, weshalb dieser bei der Modellanwendung auch separat betrachtet werden kann.¹³⁰ Von dieser

¹²⁸ Vgl. hierzu und zu diesem Abschnitt Goodhue, Thompson (1995), S. 213 ff.

¹²⁹ Eigene Darstellung in Anlehnung an Goodhue, Thompson (1995), S. 215

¹³⁰ Vgl. Goodhue, Thompson (1995), S. 223

um die Nutzungsdimension **verkürzten Form des TPC-Modells** machen viele Veröffentlichungen außerhalb der Akzeptanzforschung Gebrauch, z. B. zur Bestimmung von Auswirkungen oder von geeigneten Anwendungsmöglichkeiten neuer Technologien.¹³¹

2.1.4 Implikationen für die Untersuchung

Die vorgestellten Theorien bieten eine wichtige Grundlage für die Erklärung und bewusste Beeinflussung von Phänomenen im vorliegenden Untersuchungsfeld. Wesentliche theorienbezogene Erklärungs- und Gestaltungsbeiträge sowie daraus resultierende Ableitungen für das Vorgehen in der vorliegenden Arbeit sind in Tabelle 1 aufgeführt.

Ziel	Theorie	Erklärungs- und Gestaltungsbeitrag	Implikation für die Arbeit
Strategische Bedeutung von Technologien	RBV	<ul style="list-style-type: none"> - Es besteht eine wettbewerbsrelevante Notwendigkeit für Unternehmen zur Übernahme von externen Ressourcen. - Hierzu bedarf es einer Identifikation von erfolgskritischen Technologien. 	<ul style="list-style-type: none"> - Prüfung der Bedeutung von ML für Logistikbranche - Identifikation der Stärken und Schwächen von ML
	CBV	<ul style="list-style-type: none"> - Die Übernahme von erfolgskritischen Technologien muss mit dem Aufbau von vorteilhaften Fähigkeiten verbunden sein. 	<ul style="list-style-type: none"> - Ermittlung der Fähigkeiten und Auswirkungen von ML in der Logistik
	DCV	<ul style="list-style-type: none"> - Die aufzubauenen Fähigkeiten müssen eine Reaktion auf schnelle externe Veränderungen ermöglichen. - Hierzu bedarf es einer internen Anpassung der Unternehmen. - Im Falle von Schlüsseltechnologien soll anstatt eines Zukaufs deren feste Integration in die Organisation erfolgen. 	<ul style="list-style-type: none"> - Ermittlung von zukünftigen Entwicklungen im Untersuchungsfeld - Ermittlung des Status Quo von Unternehmen in Bezug auf die benötigten Voraussetzungen von ML im Sinne eines Branchendurchschnitts - Annahme einer Eigenentwicklung für den Gestaltungsansatz
	MBV	<ul style="list-style-type: none"> - Das Erreichen von Wettbewerbsvorteilen ist von der Positionierung der Unternehmen am Markt abhängig. 	<ul style="list-style-type: none"> - Ermittlung des Status Quo und zukünftiger Entwicklungen der Logistikbranche in Bezug auf ML
	DOI	<ul style="list-style-type: none"> - Die Übernahme von Technologien ist abhängig von der Adoptionsbereitschaft der Organisationsmitglieder. - Der damit verbundene Prozess erfordert eine Sammlung verschiedener Informationen, u. a. zu Anwendungsbereichen, und ist aktiv von den Unternehmen zu gestalten. 	<ul style="list-style-type: none"> - Betrachtung des Einsatzes von ML auf Gesamtorganisations- und Individualenebene - Bereitstellung von Informationen zu ML für die Aktivitäten entlang des gesamten Adoptionsprozesses
Adoption von Technologien	TOE	<ul style="list-style-type: none"> - Der Adoptionsprozess wird von vielen Faktoren in Bezug auf die Merkmale der Technologie, der Organisation und des Umfeldes beeinflusst, die jeweils kontextbezogen zu bestimmen sind. 	<ul style="list-style-type: none"> - Ermittlung relevanter Einflussfaktoren für das Untersuchungsfeld - Einbindung der designierten Nutzer von ML zur Informationserhebung
	MTO	<ul style="list-style-type: none"> - Die Gestaltung des Einsatzes von (digitalen) Technologien muss über eine reine Technologiebetrachtung hinausgehen und u. a. soziale und organisatorische Maßnahmen beinhalten. - Hierbei sind insbesondere die Schnittstellen der einzelnen Dimensionen zu betrachten. 	<ul style="list-style-type: none"> - Berücksichtigung verschiedener Gestaltungsdimensionen bei der Entwicklung von Maßnahmen für den Einsatz von ML - Prüfung von Wechselwirkungen zwischen den Maßnahmen

¹³¹ Eine Übersicht findet sich in Spies et al. (2020), S. 402 ff. Ein weiteres Beispiel für die Ermittlung von Anwendungsmöglichkeiten stellt die Arbeit von Shin, Dunston (2008) dar.

TPC	<ul style="list-style-type: none"> - Die Adoptionsbereitschaft resultiert aus der Erreichung festgelegter Leistungsziele. - Die Zielerreichung hängt von der Eignung der Technologie für die Aufgaben sowie von einer Verwendung durch die Nutzer ab. - Für eine Prüfung, die für beide Dimensionen entkoppelt stattfinden kann, sind kontextbezogene Merkmale zu bestimmen. 	<ul style="list-style-type: none"> - Ermittlung der Anwendungsbereiche und Fähigkeiten von ML anhand von Technologie- und Problemmerkmalen - Ermittlung übergreifender Faktoren mit Einfluss auf die Nutzung von ML anstatt Akzeptanzuntersuchung - Einbindung der designierten Nutzer von ML zur Informationserhebung
-----	---	---

Tabelle 1: Beiträge und Implikationen der forschungsleitenden Theorien

2.2 Logistikmanagement

In diesem Unterkapitel erfolgt eine Analyse und Spezifizierung der prozessualen Dimension des Untersuchungsfeldes, was ausgehend von dem Logistikverständnis der vorliegenden Arbeit eine Auseinandersetzung mit Logistiksystemen und -prozessen umfasst. Letzteres mündet in einer Abgrenzung relevanter Entscheidungsprozesse für die Arbeit.

2.2.1 Logistik und Logistiksysteme

Seit dem Aufkommen des Logistikbegriffes in den 1950er Jahren in Wissenschaft und Praxis hat sich dessen Bedeutung mehrfach gewandelt.¹³² Bis in die Gegenwart finden sich hierzu unterschiedliche Auffassungen, was v. a. auf das breite Aufgabenspektrum und den interdisziplinären Charakter der **Logistik** zurückzuführen ist.¹³³ Den Untersuchungen in der vorliegenden Arbeit wird die Definition nach *Straube (2020)* zugrunde gelegt:

„Logistik umfasst die Gestaltung des Wertschöpfungsnetzwerks sowie die Planung des Kundenauftragsprozesses und die Erfüllung von Kundenaufträgen. Die dabei zum Einsatz kommenden Informationssysteme, Technologien und Managementkonzepte dienen der Ausrichtung aller an der Leistungserstellung beteiligten Akteure und Prozesse auf die Kundenanforderungen hinsichtlich Servicequalität, Kundennutzen, Kosteneffizienz und Nachhaltigkeit.“¹³⁴

Entsprechend diesem ganzheitlichen Begriffsverständnis wirkt die Logistik über Funktionsbereichs- und Unternehmensgrenzen von den Kunden bis zu allen Lieferanten. Sie stellt damit eine **Querschnittsfunktion** entlang der gesamten Wertschöpfungskette dar, indem sie sowohl die Materialflüsse als auch die damit verbundenen Informationsflüsse innerhalb sowie zwischen den beteiligten Instanzen und Funktionen abstimmt.¹³⁵ Ziel dieser Integrationsfunktion ist eine kundenorientierte Leistungserfüllung, welche entsprechend der steigenden Bedeutung der **Logistik als Wettbewerbsfaktor** über die primären logistischen Aufgaben im Sinne einer

¹³² Vgl. *Straube (2004)*, S. 28

¹³³ Vgl. *BVL (2010)*, S. 1

¹³⁴ *Straube (2020)*, S. 7

¹³⁵ Vgl. *Pfohl (2010)*, S. 42 f.; *Straube (2004)*, S. 31; *Schuh, Stich (2013)*, S. 11

„wirtschaftlichen und termingerechten Produktion, Bereitstellung und Lieferung von Kunden bestellter Waren, Materialien, Produkte und Dienstleistungen“¹³⁶ hinausgeht.

Im Falle einer systemorientierten Betrachtung von spezifischen logistischen Einheiten wird von **Logistiksystemen** gesprochen. Hierbei handelt es sich im wirtschaftlichen Sinne um Systeme zur raumzeitlichen Gütertransformation, d. h. zur Bewegung und Lagerung von Gütern.¹³⁷ Die Transformation verknüpft Systeme zur Güterbereitstellung in Form von Industrieunternehmen mit Systemen zur Güterverwendung, wozu auch die Endkunden zählen. Logistiksysteme können durch unterschiedliche Merkmale systematisiert werden. Aus institutioneller Sicht wird in **Industrie-, Handels- und Dienstleistungslogistik** unterschieden, wobei im Falle der beiden erstgenannten eine zusätzliche Separierung in innerbetriebliche und zwischen- bzw. außerbetriebliche Logistiksysteme sinnvoll ist.¹³⁸

Eine weitere gängige Unterscheidung der Systeme wird aus funktionaler Sicht in Hinblick auf verschiedene Phasen der logistischen Leistungserstellung vorgenommen. Entsprechend des logistischen Grundprinzips der Flussorientierung erfolgt hierbei eine Ausrichtung am typischen Materialfluss der Gütertransformation. Dieser beginnt beim Beschaffungsmarkt in Form von Lieferanten, verläuft entlang des Produktionsprozesses und endet beim Absatzmarkt in Form der Kunden, von wo aus eine Rückführung in Form einer Entsorgung stattfinden kann. Hieraus ergeben sich die generischen logistischen Systeme der **Beschaffungs-, Produktions-, Distributions- und Entsorgungslogistik**.¹³⁹ Während die Produktionslogistik ein innerbetriebliches Logistiksystem darstellt und deshalb auch als Intra- oder Werkslogistik bezeichnet wird, handelt es sich bei den drei anderen Ausprägungsformen um zwischen- oder außerbetriebliche Logistiksysteme.¹⁴⁰ Zusätzlich zu diesen vier materialflussorientierten Systemen werden häufig die **Entwicklung** und der **Vertrieb** als zwei weitere Systeme der Logistik berücksichtigt.¹⁴¹ Die Gesamtheit der logistischen Systeme von Unternehmen entlang des Materialflusses wird analog zum Begriff der Wertschöpfungskette als Logistikkette oder als Supply Chain bezeichnet¹⁴², wobei letzterer im Zusammenhang mit dem häufig als synonym für die Logistik genutzten Begriff des **Supply Chain Managements (SCM)** steht¹⁴³. Entgegen der Semantik dieser Begriffe handelt es sich bei logistischen Systemen in der Praxis jedoch weniger um Ketten, sondern vielmehr um Netzwerke, die oft aus unterschiedlichen Akteuren mit komplexen Verbindungen bestehen¹⁴⁴, sodass in der Literatur – und auch in der vorliegenden Arbeit – synonym von **Logistiknetzwerken** gesprochen wird.

¹³⁶ Straube (2004), S. 27

¹³⁷ Vgl. hierzu und zum folgenden Satz Pfohl (2010), S. 3 f.

¹³⁸ Ein Unternehmen kann sich aus einem oder mehreren Betrieben zusammensetzen. Der Begriff Betrieb beschreibt eine technische Einheit, in der Produktions- und Logistiktätigkeiten verrichtet werden, wie z. B. ein Produktionswerk. Vgl. Pfohl (2010), S. 15 f.

¹³⁹ Vgl. Pfohl (2010), S. 16 f.

¹⁴⁰ Vgl. Gudehus (2010), S. 7

¹⁴¹ Vgl. Straube (2004), S. 61

¹⁴² Vgl. Arnold et al. (2008), S. 4 f.

¹⁴³ Vgl. Straube (2004), S. 33 f.

¹⁴⁴ Vgl. Gudehus (2010), S. 16 ff.

2.2.2 Logistikprozesse

Die Aktivitäten innerhalb der einzelnen Logistiksysteme werden als **Logistikprozesse** bezeichnet und sind stark miteinander vernetzt. Für die Systematisierung von Logistikprozessen existieren verschiedene Möglichkeiten, die hinsichtlich ihrer Abgrenzungsmerkmale, der betrachteten Granularität und etwaiger Domänenspezifikation variieren. Neben einer funktionalen Unterscheidung in Hinblick auf korrespondierende Logistiksysteme können die Prozesse entsprechend ihres Zeithorizonts betrachtet werden. In Analogie zur Unternehmensplanung resultieren daraus verschiedene Planungs- und Realisierungsebenen, die wie folgt unterschieden werden können:

- strategische Ebene: langfristig erfolgswirksame Planung zur Festlegung der Grundstruktur der Logistiksysteme,
- taktische Ebene: mittelfristige Planung zur Ausgestaltung der Systeme,
- operative Ebene: kurzfristige Planung zur Anpassung der Systeme sowie die Realisierung der Kundenaufträge.¹⁴⁵

Die dargestellten Ebenen zeigen, dass die **Planung** in Bezug auf verschiedene Zeithorizonte unterschieden werden kann, die von Aufgaben für mehrere Jahren, z. B. die Gestaltung von Logistiknetzwerken, bis zur Planung des Tagesgeschäftes, z. B. die Behebung von Störungen, reichen können, wobei die eher kurzfristigen Planungen auch als **Steuerung** bezeichnet werden. Sowohl die Planung als auch die Steuerung werden als vernetztes und ganzheitliches Denken zur systematischen Lösung eines Problems unter Erfassung komplexer Zusammenhänge in Unternehmen verstanden.¹⁴⁶ Sie dienen als übergeordnete, gestalterische Tätigkeiten der anforderungsgerechten **Realisierung der logistischen Leistungserstellung**, wozu im originären Verständnis die Prozesse des Transports, des Umschlags, der Kommissionierung, der Verpackung und der Lagerung zählen.¹⁴⁷ Zusätzlich zu den drei Ebenen bedarf es noch einer Berücksichtigung überwachender Logistikprozesse, die unter dem Begriff der **Kontrolle** subsumiert werden.¹⁴⁸ Im Sinne des klassischen Managementprozesses führen die Kontrollaktivitäten zu einer Rückkopplung von Informationen aus der Leistungserstellung, sodass sie die Informationsgrundlage sowie den Impuls für die vorgelagerten Planungsebenen bilden.¹⁴⁹ Die Planungs-, Steuerungs-, Realisierungs- und Kontrollaktivitäten stellen die **Aufgabenarten** der Logistik dar.¹⁵⁰

Entsprechend des in Kapitel 1.2 beschriebenen Untersuchungsfeldes findet in der vorliegenden Arbeit eine Beschränkung auf die drei Aufgabenarten der Planung, Steuerung und Kontrolle statt. In Abgrenzung zur logistischen Leistungserstellung werden die damit verbundenen

¹⁴⁵ Vgl. Straube (2004), S. 61; Schuh, Stich (2013), S. 11; Arnold et al. (2008), S. 9 f.

¹⁴⁶ Vgl. Adam (1993), S. 3

¹⁴⁷ Vgl. Schuh, Stich (2013), S. 9 f.; Arnold et al. (2008), S. 6 f.

¹⁴⁸ Im weiteren Verlauf wird die Kontrolle auch als Überwachung bezeichnet.

¹⁴⁹ Vgl. Schreyögg, Koch (2020), S. 9 f.

¹⁵⁰ Vgl. Pfohl (2010), S. 8

Managementaktivitäten als **Logistikmanagement** bezeichnet.¹⁵¹ Unter Berücksichtigung der zuvor genannten Möglichkeiten und in Anlehnung an die Supply Chain Planning (SCP) Matrix von *Rohde et al. (2000)* werden die Prozesse des Logistikmanagements in Abbildung 12 nach Zeithorizonten und den in der Arbeit betrachteten logistischen Systemen systematisiert. Diese generalisierten Prozesse – die in der Praxis aus einer Vielzahl weiterer Teilaktivitäten bestehen – sind als logistische Hauptaufgaben aus Sicht von Industrieunternehmen zu verstehen und repräsentieren bedeutende Entscheidungsprobleme im Kontext der Logistik.¹⁵² Entsprechend dieses Zusammenhangs wird in Bezug auf die Planungs-, Steuerungs-, und Kontrollaktivitäten des Logistikmanagements im weiteren Verlauf auch der Begriff der **logistischen Entscheidungsprozesse** verwendet.

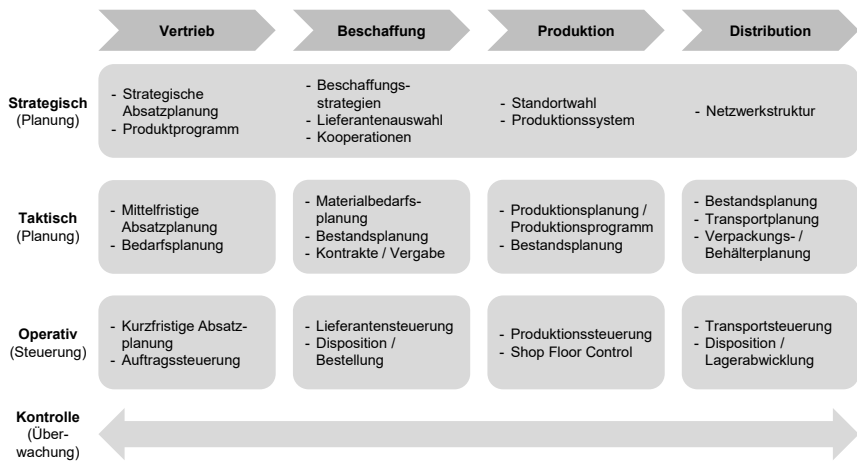


Abbildung 12: Systematisierung von Prozessen im Logistikmanagement¹⁵³

2.3 Entscheidungsprozesse und -techniken

Dieses Unterkapitel stellt das Bindeglied zwischen der prozessualen und der technischen Dimension des betrachteten Untersuchungsfeldes dar, indem eine Auseinandersetzung mit Entscheidungsprozessen im logistischen bzw. allgemein im betrieblichen Kontext sowie mit den zur Unterstützung eingesetzten Techniken erfolgt. Ausgehend von einer Definition bedeutender entscheidungstheoretischer Begriffe werden notwendige Aktivitäten in Entscheidungsprozessen und Merkmale von Entscheidungssituationen erarbeitet. Zudem findet eine Betrachtung menschlicher Problemlösungsfähigkeiten statt, die zu einer Darstellung und Systemati-

¹⁵¹ Vgl. Pfohl (2016), S. 22 f.

¹⁵² Vgl. Pfohl (2010), S. 9 f.

¹⁵³ Eigene Darstellung mit Inhalten von Fleischmann et al. (2005), S. 87; Straube (2004), S. 61

sierung unterstützender Methoden und Instrumente führen. In diesem Kontext erfolgt eine Einordnung von ML, was den inhaltlichen Übergang zu dessen detaillierter Betrachtung im nachfolgenden Unterkapitel darstellt.

2.3.1 Entscheidungstheoretische Grundbegriffe

Der Ausgangspunkt von Entscheidungen stellt stets das Vorliegen von (Entscheidungs-)Problemen dar.¹⁵⁴ Ein **Problem** besteht wiederum im Falle einer Barriere, welche die Transformation eines unerwünschten Ausgangszustands in einen erwünschten End- bzw. Zielzustand verhindert.¹⁵⁵ Das Bestreben, den Endzustand zu erreichen und damit die Barriere zu überwinden, wird als **Problemlösung** definiert.¹⁵⁶ Bestehen für die Lösung des Problems verschiedene Handlungsalternativen, aus denen eine oder mehrere Möglichkeiten durch einen Entscheidungsträger (ET) ausgewählt werden, handelt es sich um eine **Entscheidung**.¹⁵⁷ Hierzu bedarf es einer Bewertung der Handlungsalternativen in Hinblick auf deren Erfolgsbeitrag, die wiederum von Umweltzuständen (Einflussfaktoren) abhängig sind, die nur partiell vom ET beeinflussbar sind. Diese verfügbaren Alternativen mit ihren Auswirkungen und den Einflussfaktoren bilden das sog. **Entscheidungsfeld** für Problemlösungen.¹⁵⁸

Der Wahlakt bei Entscheidungen entspricht einem kreativen Prozess, der mit der jeweiligen Problemlösung stets etwas „Neues“ schafft. Damit grenzen sich Probleme semantisch von **Aufgaben** ab, die lediglich ein „reproduktives Denken“ der ausführenden Instanz erfordern, da alle notwendigen Methoden für die Lösung bekannt sind.¹⁵⁹

2.3.2 Aktivitäten in Entscheidungsprozessen

Entsprechend der vorausgehenden Ausführungen sind für das Treffen geeigneter Entscheidungen mehrere Informationen notwendig u. a. zum jeweiligen Anfangs- und Endzustand, zu relevanten Umweltzuständen sowie zu möglichen Handlungsalternativen. Diese Informationen liegen ET in den meisten Fällen jedoch nicht von Beginn an vollständig vor, sondern müssen erst ermittelt werden.¹⁶⁰ Vor diesem Hintergrund werden Entscheidungen auch nicht als punktuelles Ereignis betrachtet. Vielmehr stellen sie einen zeitlichen Prozess zur Verarbeitung verschiedener Informationen dar, der als **Entscheidungsprozess** oder im betrieblichen Kontext auch als Planungsprozess¹⁶¹ bezeichnet wird.¹⁶² Aus entscheidungstheoretischer Sicht kann dieser Prozess in mehrere Phasen unterteilt werden, welche in Abbildung 13 dargestellt sind,

¹⁵⁴ Aufgrund der inhaltlichen Verbindung werden Probleme auch als Entscheidungsprobleme bezeichnet. Vgl. Riesenhuber (2006), S. 10. In der vorliegenden Arbeit werden diese Begriffe ebenfalls synonym verwendet.

¹⁵⁵ Vgl. Dörner (1979), S. 10

¹⁵⁶ Vgl. Hussy (1984), S. 114

¹⁵⁷ Vgl. Funke (2003), S. 22; Laux et al. (2018), S. 3

¹⁵⁸ Vgl. Adam (1993), S. 7

¹⁵⁹ Vgl. Dörner (1979), S. 10

¹⁶⁰ Vgl. Kahle (2001), S. 41

¹⁶¹ Vgl. Kahle (2001), S. 12

¹⁶² Vgl. Adam (1993), S. 20

und ein vereinfachtes Abbild der realen Aktivitäten darstellen. Es bestehen hohe Interdependenzen zwischen den Phasen, was insgesamt zu einer starken Verzahnung und Iteration der Aktivitäten führt und eine phasenbezogene Abgrenzung nicht immer möglich macht.¹⁶³



Abbildung 13: Phasen von Entscheidungsprozessen¹⁶⁴

Der Entscheidungsprozess beginnt mit der **Wahrnehmung eines Problems** aus dem Umfeld, welches eine Reaktion durch den ET möglich bzw. notwendig macht.¹⁶⁵ Dies erfolgt durch sog. Anregungsinformationen, die entweder direkt das zu lösende Probleme operationalisieren, z. B. mittels einer detektierten Soll-Ist-Abweichung, oder Ausgangspunkt für weitere Analysen und Entscheidungen zur Präzisierung des Problems sind.

Da Letzteres oft mit umfassenderen Aktivitäten zur Informationsbeschaffung, u. a. in Bezug auf Ursachen und tieferliegende Zusammenhänge, verbunden ist, wird die **Problempräzisierung** als Gegenstand einer separaten Phase betrachtet. Weiterhin werden in dieser Phase die **angestrebten Ziele** in Form des Endzustands, welcher die Grundlage für die Ermittlung und Bewertung der späteren Handlungsalternativen darstellt, sowie damit verbundene Restriktionen erarbeitet und präzisiert.¹⁶⁶ Die Restriktionen führen zu einer Begrenzung des Lösungsraums und können sowohl unternehmensintern als auch -extern begründet sein, z. B. in Form von Kapazitätsgrenzen, Kundennachfragen oder rechtlichen Anforderungen. Im Falle einer dynamischen Veränderbarkeit dieser Restriktionen bedarf es Prognosen zu deren möglichen zukünftigen Ausprägungen.¹⁶⁷

In der nächsten Phase werden mögliche **Handlungsalternativen** zur Lösung der Probleme ermittelt und bewertet. Zur Bestimmung der Vorteilhaftigkeit dieser Alternativen werden deren potenzielle Auswirkungen bestimmt. Dies bezieht sich sowohl auf den Erfolgsbeitrag zur je-

¹⁶³ Vgl. Adam (1993), S. 15

¹⁶⁴ Eigene Darstellung mit Inhalten aus Kahle (2001), S. 43; Adam (1993), S. 15; Haun (2016), S. 49; Laux et al. (2018), S. 12

¹⁶⁵ Vgl. hierzu und zum folgenden Satz Laux et al. (2018), S. 13; Adam (1993), S. 21

¹⁶⁶ Vgl. Adam (1993), S. 21

¹⁶⁷ Vgl. Adam (1993), S. 25

weiligen Problemlösung als auch auf mögliche Effekte auf andere Zielgrößen und Systemkomponenten.¹⁶⁸ Die Auswirkungen sind abhängig von den individuellen Umweltzuständen, die zum Realisierungszeitpunkt der jeweiligen Alternative vorliegen. Da diese vom gegenwärtigen Zustand abweichen können, bedarf es auch hier Prognosen.¹⁶⁹

Aus der Gesamtheit der bewerteten Handlungsalternativen erfolgt in im Anschluss eine **Auswahl** der geeignetsten Lösung für das jeweilige Problem. Diese Aktivität entspricht der Entscheidung im engeren Sinne.¹⁷⁰ In der nachfolgenden Realisationsphase werden die im Rahmen der Entscheidung festgelegten **Handlungen** mit etwaigen Begleitaktivitäten im betrieblichen Umfeld umgesetzt, wozu teilweise weitere Entscheidungen getroffen werden müssen.

Anschließend erfolgt die **Kontrolle** der Entscheidungen, indem die jeweiligen Auswirkungen und etwaige Abweichungen von den angestrebten Zielen im Sinne einer **Erfolgsmessung** ermitteln werden. Diese Erkenntnisse wirken zugleich als Anregungsinformation für neue Entscheidungsprozesse durch die Detektion neuer Probleme.¹⁷¹ Damit stellt die Kontrolle ein Bindeglied zwischen der Realisierung und Problemwahrnehmung dar.

Der beschriebene Prozess verdeutlicht, dass für die Lösung eines initialen Problems mehrere Teilprobleme zu lösen sind.¹⁷² Neben der Auswahl der geeignetsten Handlungsalternative sind daher auch in den restlichen Phasen mehrere Vor- bzw. **Teilentscheidungen** zu treffen, u. a. zur endgültigen Formulierung der Probleme, zur Ermittlung von Umweltzuständen und zur Bestimmung von Auswirkungen.¹⁷³ Aus diesem Grund wird der Entscheidungsprozess auch als „*ein Prozess der Lösung zahlreicher Einzelentscheidungsprobleme*“ bezeichnet.¹⁷⁴

2.3.3 Merkmale von Problemen

Problemstellungen sind in der betrieblichen Praxis sehr unterschiedlich ausgeprägt, was Auswirkungen auf die jeweiligen Lösungsmöglichkeiten und die Gestaltung der Entscheidungsprozesse hat.¹⁷⁵ Eine Systematisierung von Problemen kann anhand von deren Schwierigkeit¹⁷⁶ vorgenommen werden, wozu häufig eine merkmalsbezogene Betrachtung der Entscheidungsträger und Entscheidungssituationen stattfindet.

Für die Charakterisierung von **Entscheidungsträgern** unterscheidet *Kahle (2001)* nach deren Rationalität und Bewusstheit¹⁷⁷ sowie nach deren Anzahl, wobei für Letzteres eine Differen-

¹⁶⁸ Vgl. Adam (1993), S. 22

¹⁶⁹ Vgl. Laux et al. (2018), S. 15; Adam (1993), S. 24

¹⁷⁰ Vgl. hierzu und zum folgenden Satz Laux et al. (2018), S. 15

¹⁷¹ Vgl. Adam (1993), S. 21; Kahle (2001), S. 43 f.

¹⁷² Vgl. Pfohl (1977), S. 250

¹⁷³ Vgl. Pfohl (1977), S. 246

¹⁷⁴ Laux et al. (2018), S. 15

¹⁷⁵ Eine Übersicht findet sich in Funke (2003), S. 32 ff.

¹⁷⁶ Vgl. Hussy (1984), S. 122

¹⁷⁷ Automatisierte bzw. habitualisierte Handlungen stellen demnach keine Entscheidungen dar. Vgl. Kahle (2001), S. 10

zierung nach Individual- und Gruppenentscheidungen vorgenommen wird. *Hussy (1984)* fokussiert deren Faktenwissen und methodisches Wissen, welches u. a. durch Intelligenz, Bildung und Erfahrung unterschiedlich ausgeprägt sein kann. In Bezug auf diese beiden Wissensarten wird jeweils hinsichtlich des Umfangs, der Struktur und der Verfügbarkeit unterschieden.¹⁷⁸ Die Abhängigkeit der Entscheidungen vom Erfahrungsschatz und von den Fähigkeiten des ET wird insbesondere für die Phase der Erforschung der Handlungsalternativen gesehen, bei der sich der ET aus bestehenden Ideen und Lösungen bedient, welche für das jeweilige Problem in derselben Form genutzt oder individuell abgewandelt werden müssen.¹⁷⁹

Für die Unterscheidung individueller **Entscheidungssituationen** wird eine Abstraktion der zugrundeliegenden Probleme vorgenommen. Ausgangspunkt der Charakterisierung sind Probleme mit vollkommener Informationsverfügbarkeit, die als **wohlstrukturierte Probleme** bezeichnet werden und folgende Merkmale aufweisen:

- Das Entscheidungsfeld ist bekannt und geschlossen, sodass alle benötigten Variablen und deren Beziehung sowie eine bekannte Anzahl von Handlungsalternativen (Lösungen) vorliegen.
- Die Zielstellung kann durch numerische Ausdrücke formuliert werden und erlaubt eine eindeutige Bewertung der Handlungsalternativen hinsichtlich ihrer Vorzugswürdigkeit.
- Es ist ein effizientes Lösungsverfahren vorhanden, welches die systematische Auswahl der besten Handlungsalternative erlaubt.¹⁸⁰

Diese Ausprägung von Problemen entspricht dem in Kapitel 2.3.1 definierten Begriff einer Aufgabe, zu deren Lösung es keinerlei Kreativität des ET bedarf. Vielmehr besteht eine endliche Anzahl von **Regeln**, mit denen das jeweilige Problem gelöst werden kann.¹⁸¹ Bei den meisten Problemen im Unternehmenskontext sind diese Voraussetzungen jedoch nur partiell oder gar nicht gegeben.¹⁸² Für die jeweils fehlenden Informationen existieren verschiedene Ausprägungsformen, die als **Strukturmängel** oder Defekte beschrieben werden und das Fehlen von eindeutigen Zielsetzungen und Bewertungsmöglichkeiten sowie von Handlungsalternativen und deren Auswirkungen umfassen. Die Ursache für das Vorliegen dieser sog. schlecht strukturierten Probleme¹⁸³ im Unternehmenskontext ist die Komplexität vieler betrieblicher Entscheidungssituationen. Der Begriff der **Komplexität** im Kontext der Entscheidungstheorie wurde von *Dörner (1979)* aufgenommen und fungiert als Oberbegriff für verschiedene Eigenschaften, die nachfolgend beschrieben werden.

Ausgangspunkt der Betrachtungen zur Komplexität sind die strukturellen Eigenschaften von Problemen. Demnach müssen bei Entscheidungen verschiedene Einflussfaktoren (Variablen)

¹⁷⁸ Vgl. *Hussy (1984)*, S. 136 ff.

¹⁷⁹ Vgl. *Adam (1993)*, S. 22

¹⁸⁰ Vgl. *Kahle (2001)*, S. 19; *Adam (1993)*, S. 7 ff.

¹⁸¹ Vgl. *Kahle (2001)*, S. 19 f.

¹⁸² Vgl. hierzu und zum folgenden Satz *Adam (1993)*, S. 10 ff.

¹⁸³ Hierbei kann es sich um wohldefinierte, unvollständig formulierte Probleme und um schlecht definierte Probleme handeln. Die Definiertheit ergibt sich aus der Existenz von Informationen zum Ausgangs- und Endzustand sowie zur Bewertung der Lösung. Vgl. *Kahle (2001)*, S. 20 f.

berücksichtigt werden, die den Zustand des problemrelevanten Umfeldes beschreiben. Im Falle einer Vielzahl von Variablen wird auch von einer **Komplexität im engeren Sinne** gesprochen.¹⁸⁴ Diese Variablen stehen teilweise in Verbindung zueinander, wobei die damit verbundene Art und Anzahl durch das Merkmal der **Vernetztheit** abgebildet wird. Im Rahmen einer Problemlösung kann sich die Entscheidungssituation und damit die Informationsgrundlage zur Auswahl von Handlungsalternativen verändern, ohne dass der ET aktiv eingreift.¹⁸⁵ Das führt fallweise dazu, dass initial geeignete Handlungsalternativen sich hinsichtlich ihrer Vorzugswürdigkeit verändern und neue Alternativen auftreten. Das Entscheidungsfeld wird in diesen Fällen als offen bezeichnet. Der Umfang und die Geschwindigkeit von Veränderungen werden über das Merkmal der **Dynamik** dargestellt, welche die Entscheidungssituationen um eine Zeitkomponente ergänzt.¹⁸⁶ Ein weiteres Merkmal betrifft die **verfügbare Zeit** für den ET zwischen der Wahrnehmung eines Problems und dessen Lösung, die im Unternehmenskontext stets limitiert ist.¹⁸⁷ Die Veränderlichkeit der Entscheidungssituation lässt einen zusätzlichen Zeitdruck zum Handeln entstehen.¹⁸⁸ Auch der angestrebte Endzustand einer Problemlösung wird zur Unterscheidung von Entscheidungssituationen herangezogen. Demnach werden die Anzahl und Beziehung der adressierten Ziele, welche teilweise widersprüchlich zueinanderstehen können, unter dem Merkmal der **Polytelie** zusammengefasst.¹⁸⁹

Wie eingangs beschrieben, liegen in der Praxis nur selten alle benötigten Informationen für den ET vor. Die Vollständigkeit der Informationen zur Ermittlung der Auswirkungen der möglichen Handlungsalternativen wird als **Ungewissheit** bezeichnet. Ein Mangel an Informationen kann entweder aus fehlenden Beschaffungsmöglichkeiten für den ET oder einer grundsätzlichen Nichtverfügbarkeit resultieren.¹⁹⁰ In Abhängigkeit der sog. **Datensituation** wird in die drei folgenden Typen von Ungewissheit¹⁹¹ unterschieden:

- Sicherheit: Alle benötigten Informationen sind vorhanden, um für jede Handlungsalternative die Auswirkungen eindeutig zu ermitteln. Hierzu werden auch Situationen gezählt, in denen zwar einige Informationen fehlen, deren Ausprägungen aber mit einer sehr hohen Wahrscheinlichkeit angenommen werden können, sodass sie als „quasi-sicher“ gelten. In beiden Fällen handelt es sich um **deterministische Entscheidungssituationen**.
- Risiko: Es sind nicht alle benötigten Informationen vorhanden, sodass mehrdeutige Beziehungen zwischen Handlungsalternativen und Auswirkungen entstehen. Für die jeweiligen Ausprägungen können zwar Wahrscheinlichkeiten angegeben werden;

¹⁸⁴ Vgl. Hussy (1984), S. 132

¹⁸⁵ Vgl. Dörner (1979), S. 19

¹⁸⁶ Vgl. Funke (2003), S. 134

¹⁸⁷ Vgl. Adam (1993), S. 23

¹⁸⁸ Vgl. Dörner (1979), S. 20

¹⁸⁹ Vgl. Funke (2003), S. 133 f.

¹⁹⁰ Vgl. Kahle (2001), S. 115 f.

¹⁹¹ Neben diesen drei wesentlichen Ausprägungen existieren weitere Sonder- und Mischfälle. Vgl. Kahle (2001), S. 116; Bamberg et al. (2012), S. 123

diese verändern sich jedoch bei einer Wiederholung, da sie einer nicht zu vernachlässigenden Streuung unterliegen. Es handelt sich um probabilistische bzw. **stochastische Entscheidungssituationen**.

- Unsicherheit im engeren Sinne: Es fehlen Informationen in so einem Maße, dass keine verlässlichen Wahrscheinlichkeiten für das Eintreten der Auswirkungen ermittelt werden können, da diese z. B. vom Verhalten Dritter abhängig sind. Es wird daher auch von einer „Einmaligkeit der Entscheidung“ gesprochen.¹⁹²

Während der erste Typ zu einer „sicheren“ Ermittlung der Auswirkungen von Handlungsalternativen führt, sind bei den beiden letztgenannten Typen ausschließlich bzw. in Teilen nur „unsichere“ Aussagen möglich. Daher werden diese Entscheidungssituationen im weiteren Sinne unter dem Begriff der **Unsicherheit** subsumiert.

Die genannten Merkmale sind mit ihren Ausprägungen für komplexe Probleme in der Tabelle 2 dargestellt. Diese sind als Indikatoren zur qualitativen Einschätzung der Problemschwierigkeit zu verstehen, wie sie zumeist in der Betriebswirtschaftslehre Anwendung findet.¹⁹³ Demnach kann im betrieblichen Kontext von **komplexen Problemen** ausgegangen werden, wenn viele interne und externe Variablen existieren, die in teils nichtlinearen Beziehungen voneinander abhängig sind und die sich verändern können, wobei deren aktuelle und zukünftige Ausprägungen teilweise unbekannt sind. Zugleich liegen mehrere, teils konfliktäre Zielsetzungen sowie ein geringes Zeitkontingent zur Problemlösung für den ET vor. Auch wenn die Merkmalsausprägungen für jedes Problem unterschiedlich ausfallen, lassen sich für bestimmte betriebliche Prozesse aufgrund der generalisierten Voraussetzungen des jeweiligen Systems **typische Entscheidungssituationen** ableiten. Im Falle der Logistik wird dazu angenommen, dass deren inhärente Eigenschaften vermehrt zu einer ausgeprägten Komplexität der Probleme in diesem Bereich führen. Auch ist aufgrund der beeinflussenden Trends davon auszugehen, dass die Komplexität in Zukunft weiter zunehmen wird.¹⁹⁴

Merkmalsausprägung	Beschreibung	Ausprägung für komplexe Probleme	Korrespondierende Eigenschaft der Logistik
Anzahl der Variablen	Anzahl der Variablen, die für Problemlösung relevant sind	Viele Variablen („strukturell komplexe Probleme“)	Viele Variablen mit hoher Abhängigkeit aufgrund der logistischen Querschnittsfunktion
Vernetztheit der Variablen	Anzahl und Art der Beziehung der Variablen	Viele, teils nichtlineare Beziehungen der Variablen („hoch vernetzte Probleme“)	
(Eigen-)Dynamik	Veränderung der Variablen auch ohne Eingreifen des ET	Hohe und schnelle Veränderung der Variablen („dynamische Probleme“)	Hohe Dynamik entsprechend der raumzeitlichen Gütertransformation
Zeit	Verfügbare Zeit für Problemlösung	Geringeres Zeitkontingent („zeitkritische Probleme“)	Hoher Zeitdruck durch Ausrichtung an Leistungserstellung und enge Taktung

¹⁹² Vgl. Kahle (2001), S. 116 ff.; Laux et al. (2018), S. 35, 54 f.; Bamberg et al. (2012), S. 39

¹⁹³ Die Operationalisierung der Komplexitätsmerkmale von Problemen wird stattdessen in der theoretischen Informatik im Rahmen der Komplexitäts- und Berechenbarkeitstheorie verfolgt.

¹⁹⁴ Vgl. Handfield et al. (2013), S. 8

Ungewissheit	Zugänglichkeit und Verfügbarkeit aller Informationen	Viele fehlende Informationen („unsichere Probleme“)	Geringe Verfügbarkeit aufgrund externer Abhängigkeiten
Polytelie	Anzahl und Beziehung der Ziele	Mehrere, sich teils widersprechende Ziele („multikriterielle Probleme“)	Viele Zielkonflikte durch mehrere Stakeholder und ganzheitliche Gestaltung

Tabelle 2: Merkmale von komplexen Problemen¹⁹⁵

2.3.4 Manuelle Ausführung von Entscheidungen

Die dargestellten Aktivitäten in Entscheidungsprozessen, auch im Falle von komplexen Problemen, müssen grundsätzlich alle von menschlichen ET bewältigt werden. Zu deren Ausführung verfügt der Mensch über verschiedene kognitive Fähigkeiten, die u. a. für die informationsbezogene Aufnahme, kurz- bis langfristige Speicherung, Transformation, Verbalisierung und Ausgabe genutzt werden können.¹⁹⁶ Es zeigt sich jedoch, dass diese Fähigkeiten bei den Menschen unterschiedlich ausgeprägt sind. Zudem sind ihnen – auch im Falle einer ausgeprägten Intelligenz der jeweiligen ET – **natürliche Grenzen** gesetzt.¹⁹⁷ Dies führt dazu, dass bei einer steigenden Komplexität die jeweiligen Probleme nicht oder nur mit einem sehr hohen zeitlichen Aufwand durch den Menschen lösbar sind, wobei dieser Aufwand oft nicht mit betrieblichen Restriktionen zu vereinen ist.

Zusätzlich lässt sich in der Realität beobachten, dass die funktionale Problemlösungsfähigkeit des Menschen durch verschiedene physische, körperliche und soziale Faktoren beeinflusst wird, z. B. durch Gefühle wie Angst und Mitleid, durch eine Gruppendynamik oder durch das Verfolgen von eigenen Interessen, welche nicht im Einklang mit der eigentlichen Zielstellung stehen. Diese Einflussfaktoren resultieren in einer Abweichung von rationalen Handlungen in Entscheidungsprozessen, wie sie in der klassischen Entscheidungstheorie angenommen werden.¹⁹⁸ Die damit verbundenen „Regelverletzungen“ der ET können bewusst und unbewusst ablaufen und führen dazu, dass Probleme nicht richtig wahrgenommen, Ziele falsch definiert und Handlungen nicht richtig gewählt oder ausgeführt werden.¹⁹⁹ Im Detail kann von folgenden systematischen **Fehlern bei der manuellen Ausführung** von Entscheidungsprozessen gesprochen werden:

- Fehler bei der Informationsbeschaffung, z. B. höhere Bewertung der eigenen Probleme bzw. Ziele, falsche Einschätzung der Eintrittswahrscheinlichkeiten von Ereignissen, selektive Auswahl und Ignoranz von Informationen,
- Fehler bei der Informationsverarbeitung, z. B. uneinheitliche Verwendung von Bewertungskriterien, keine iterative Anpassung von Bewertungen bei neuen Informationen,

¹⁹⁵ Inhalte der ersten drei Spalten als Synthese aus Hussy (1993), S. 141 ff.; Dörner (1979), S. 18 ff.; Funke (2003), S. 126 ff.

¹⁹⁶ Vgl. Hussy (1993), S. 42 f.; Dörner (1979), S. 111 f. Eine weiterführende Erklärung der kognitiven Fähigkeiten zur Lösung von Problemen erfolgt in Kapitel 2.4.1.1.

¹⁹⁷ Vgl. Hussy (1993), S. 9 ff.

¹⁹⁸ Vgl. Adam (1993), S. 19

¹⁹⁹ Vgl. Funke (2003), S. 238

Fehleinschätzung der Auswirkungen von nichtlinearen Beziehungen (exponentielles Wachstum), Erstellung von Prognosen anhand weniger Größen oder Nutzung etablierter Vorgehensweisen, auch wenn diese nicht mehr geeignet sind,

- Fehler bei der Auswahl von Handlungsalternativen, z. B. Überschätzung eigener Fähigkeiten in Form einer Kontrollillusion.²⁰⁰

2.3.5 Technische Unterstützung von Entscheidungen

Zur Kompensation der Limitationen von menschlichen Problemlösungsfähigkeiten existiert eine Vielzahl von technischen Lösungen, die ET bei den Aktivitäten in Entscheidungsprozessen unterstützten können. Diese werden als Problemlösungs- oder **Entscheidungstechniken** bezeichnet und setzen sich aus den zwei Komponenten der Entscheidungsmethode und des Entscheidungsinstruments zusammen.²⁰¹ In den nachfolgenden Abschnitten werden diese Techniken systematisiert und beschrieben, wozu auch eine Abgrenzung von modell- und datengestützten Techniken gehört.

2.3.5.1 Systematisierung

Im Falle von **Entscheidungsmethoden** handelt es sich um systematische Abfolgen von Regeln in Form von Verfahrensvorschriften.²⁰² Zur erleichterten Ausführung dieser Methoden werden Entscheidungsinstrumente eingesetzt, welche die technische Aufnahme, Verarbeitung, Speicherung und/oder Bereitstellung der jeweiligen Informationen übernehmen.²⁰³ In der Praxis werden bereits vielfach **rechnergestützte Entscheidungsinstrumente** in Form von IT-Systemen eingesetzt, bei denen die jeweilige Entscheidungsmethode in einen ausführbaren Algorithmus überführt wird. Bedeutende Instrumente sind u. a. Entscheidungsunterstützungssysteme (DSS), Expertensysteme sowie Business-Intelligence-Systeme (BI).²⁰⁴ BI-Systeme können bei der Wahrnehmung und Präzisierung von Problemen unterstützen, indem sie u. a. mittels Verfahren der deskriptiven Statistik strukturierte Daten analysieren und in Form von Analysen und Reports aufbereiten.²⁰⁵ Expertensysteme dienen der Auswahl geeigneter Handlungsalternativen, indem sie menschliches Wissen für spezifische Entscheidungssituationen ausgeben.²⁰⁶ DSS können je nach Gestaltung Informationen entlang des gesamten Entscheidungsprozesses bereitstellen und dienen daher oft als Oberbegriff für alle rechnergestützten Entscheidungstechniken.²⁰⁷

Da die systemseitige Realisierung von Entscheidungstechniken in Form der jeweiligen Instrumente maßgeblich von den zugrundeliegenden Entscheidungsmethoden abhängt, wurde in

²⁰⁰ Vgl. Funke (2003), S. 239 f.

²⁰¹ Vgl. Pfohl (1977), S. 187

²⁰² Vgl. Pfohl (1977), S. 188

²⁰³ Vgl. Pfohl (1977), S. 209

²⁰⁴ Vgl. Mortenson et al. (2015), S. 588 f.

²⁰⁵ Vgl. Holsapple et al. (2014), S. 131

²⁰⁶ Eine weiterführende Erklärung von Expertensystemen erfolgt in Kapitel 2.4.2.2.

²⁰⁷ Vgl. Arnott, Pervan (2015), S. 128

der vorliegenden Arbeit eine Systematisierung anhand der Methoden vorgenommen, die in Abbildung 14 zusammenfassend mit exemplarischen Vertretern dargestellt ist.

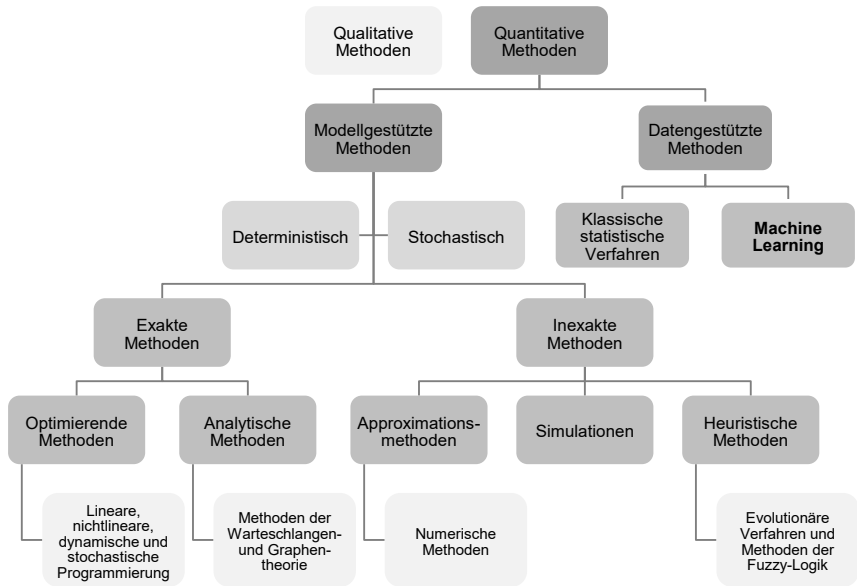


Abbildung 14: Systematisierung von Methoden für Entscheidungstechniken²⁰⁸

Auf oberster Ebene kann in qualitative und quantitative Methoden unterschieden werden. Zu qualitativen Methoden gehören u. a. die Delphi-Methode und die Szenario-Technik, welche insbesondere zur Ermittlung der Auswirkungen von Handlungsalternativen eingesetzt werden, sowie die Entscheidungsmatrix und Nutzwertanalyse, welche der Bewertung von Handlungsalternativen dienen.²⁰⁹ Dieser Methodenbereich ist für die vorliegende Arbeit nicht relevant. Die stattdessen im Fokus stehenden **quantitativen Methoden** bilden ein breites Feld an Ausprägungen und basieren auf mathematischen und statistischen Verfahren. Die bislang dominierende Nutzung dieser Methoden erfolgt im Rahmen des **modellgestützten Ansatzes**, der zusammen mit den dazugehörigen Unterscheidungsmerkmalen im nachfolgenden Abschnitt beschrieben wird.

2.3.5.2 Modellgestützte Entscheidungstechniken

Modellgestützte Entscheidungstechniken sehen eine Überführung realer Entscheidungssituationen in symbolische Modelle vor, indem die problemrelevanten Eigenschaften aus der Praxis

²⁰⁸ Eigene Darstellung. Die Systematisierung gilt insbesondere für Entscheidungsmodelle und ist als Synthese verschiedener Veröffentlichungen zu verstehen, welche hinsichtlich der betrachteten Teilbereiche und der Unterscheidungsmerkmale variieren. Weitere Abgrenzungsmöglichkeiten finden sich u. a. in Laux et al. (2018), S. 54 und Arnold et al. (2008), S. 428 ff.

²⁰⁹ Vgl. Adam (1993), S. 351; Kahle (2001), S. 52

durch den Menschen erfasst, strukturiert und mittels mathematischer Syntax formalisiert werden.²¹⁰ Anhand dieser abstrahierten Realität kann durch Anwendung der entsprechenden Methode die Lösung der Probleme logisch erschlossen werden.²¹¹ Die Ergebnisse sind anschließend anhand der realen Situation überprüfbar, was zu einer Anpassung des Modells durch den Menschen führen kann (siehe Abbildung 15).²¹²




Abbildung 15: Prinzip von modellgestützten Entscheidungstechniken²¹³

In Bezug auf die modellbezogenen Zielsetzungen zur Unterstützung der Aktivitäten in Entscheidungsprozessen wird in die drei Modellarten der Beschreibungsmodelle, der Erklärungs- bzw. Prognosemodelle sowie der Entscheidungsmodelle unterschieden.²¹⁴ Diese werden nachfolgend mit assoziierten Methoden beschrieben, wobei keine exklusive Zuordnung der Methoden zu den Phasen besteht.

Beschreibungsmodelle stellen deskriptive Informationen zur Entscheidungssituation dar. In der Logistik werden sie u. a. zur Erfassung von Problemen, z. B. in Form von Störungen, sowie für die Bereitstellung von Zusatzinformationen in Entscheidungsprozessen in Form von Kennzahlen aus dem Logistikcontrolling eingesetzt.²¹⁵ Hierbei kann es sich u. a. um Zeit- oder Soll-Ist-Vergleiche handeln. Insbesondere im Falle von schlecht definierten Problemen werden auch Heuristiken zur Gewinnung von Informationen eingesetzt.²¹⁶

Eine Erfassung von Zusammenhängen zwischen Variablen in Form empirischer Gesetzmäßigkeiten oder Hypothesen findet mittels **Erklärungsmodellen** statt, zu denen auch **Prognosemodelle** gehören. Letztere kommen in der Logistik u. a. bei der Ermittlung zukünftiger Ausprägungen von Einflussfaktoren, wie der Nachfragemenge und der Bestandshöhe, zum Einsatz. Im Rahmen der bestehenden Prognosemodelle werden entweder klassische statistische Verfahren, insbesondere Regressionsverfahren, oder Zeitreihenanalysen angewandt, z. B. in Form der exponentiellen Glättung und des gleitenden Mittelwertes.²¹⁷ Es handelt sich demnach

²¹⁰ Vgl. Pfohl (2016), S. 261 f.

²¹¹ Vgl. Bretzke (1980), S. 8

²¹² Vgl. Koop, Moock (2018), S. 3

²¹³ Eigene Darstellung in Anlehnung an Pfohl (2016), S. 262; Koop, Moock (2018), S. 3

²¹⁴ Vgl. hierzu und zu diesem Abschnitt Bamberg et al. (2012), S. 15; Pfohl (2016), S. 262 f.

²¹⁵ Vgl. Pfohl (2016), S. 181

²¹⁶ Vgl. Kahle (2001), S. 21

²¹⁷ Vgl. Schuh, Stich (2013), S. 90 ff.; Adam (1993), S. 174 f.

v. a. um parametrisierte Verfahren, bei denen der Mensch für einzelne Parameter Annahmen treffen muss und diese in eine mathematische Funktion überführt.²¹⁸ Eine spezielle Ausprägung von Prognosemodellen stellen Simulationen dar. Im Rahmen der **Simulationsmodelle** kann durch die experimentelle Veränderung von einzelnen Parametern eine Zustandsänderung des modellierten Systems wahrgenommen werden, sodass diese Modelle insbesondere bei der Ermittlung von Auswirkungen für Handlungsalternativen im Sinne sog. What-if-Szenarien Anwendung finden.²¹⁹

Im Rahmen von **Entscheidungsmodellen** werden geeignete Handlungsalternativen ermittelt, wobei diese auf Informationen aus den vorausgehenden Aktivitäten des Entscheidungsprozesses angewiesen sind, die z. B. mittels der zuvor genannten Modelle erhoben werden können. In der Logistik werden diese u. a. zur Ermittlung optimaler Routen, Maschinenbelegungen und Dispositionsentscheidungen eingesetzt. Die assoziierten Methoden können auf oberster Ebene hinsichtlich ihres Umgangs mit den verfügbaren Informationen unterschieden werden. Es existieren deterministische Methoden, die in (quasi-)sicheren Entscheidungssituationen zum Einsatz kommen, sodass sie bei gleicher Datenlage stets zum selben Ergebnis kommen.²²⁰ Demgegenüber stehen stochastische Methoden, die bei unsicheren Situationen angewandt werden, sodass deren Ergebnisse mit Wahrscheinlichkeiten behaftet sind.²²¹ Eine weitere Abgrenzung findet hinsichtlich des Berechnungsverfahrens statt, wobei in exakte und inexacte Methoden unterschieden wird. Exakte Methoden werden bei wohlstrukturierten Problemen eingesetzt, in denen alle relevanten Informationen vorhanden sind, sodass sie in der Lage sind, optimale Lösungen für ein Problem zu finden, weshalb sie auch als Optimierungsmethoden bezeichnet werden.²²² Hierzu zählen analytische Verfahren der Warteschlangen- und Graphentheorie sowie Verfahren der mathematischen Optimierung, z. B. die lineare Programmierung – als am häufigsten vorkommende Ausprägung – sowie die nichtlineare, dynamische und stochastische Programmierung.²²³ Im Falle von schlecht strukturierten Problemen, d. h. beim Fehlen wichtiger Informationen für die Problemlösung, werden inexacte Modelle angewendet.²²⁴ Dazu gehören heuristische Methoden, bei denen eine Lösung ermittelt wird, die in der Regel nicht der optimalen Lösung entspricht.²²⁵ Ziel von Heuristiken ist es, durch eine Reduktion der Problemkomplexität in vergleichsweise kurzer Zeit brauchbare Ergebnisse, z. B. in Form einer Näherungslösung, zu ermitteln.²²⁶ Zu den Vertretern gehören verschiedene Suchverfahren aus dem Bereich der evolutionären Verfahren, wie Ameisensysteme und allge-

²¹⁸ Demgegenüber erfordern nicht- und semiparametrische Verfahren eine geringe Spezifizierung durch den Menschen. Vgl. Fahrmeir et al. (2009), S. 40, 291

²¹⁹ Vgl. Pfohl (2016), S. 273

²²⁰ Vgl. Arnold et al. (2008), S. 429

²²¹ Vgl. Laux et al. (2018), S. 54

²²² Vgl. Pfohl (2016), S. 207 f.; Briskorn (2020), S. 10

²²³ Vgl. Kahle (2001), S. 93

²²⁴ Vgl. Kahle (2001), S. 20

²²⁵ Vgl. Briskorn (2020), S. 10 f.

²²⁶ Vgl. Kahle (2001), S. 21

meine Multiagentensysteme, die Tabu-Suche und Methoden der Fuzzy-Logik. Auch Simulationen stellen im Falle der Vorgabe von Handlungsalternativen inexakte Entscheidungsmodelle dar.²²⁷ Als Übergang von inexakten zu exakten Methoden werden Approximationsmethoden angesehen, die zwar in der Regel ebenfalls keine optimale Lösung ermitteln, aber im Unterschied zu Heuristiken eine quantifizierbare Größe zur Ergebnisqualität im Sinne des erwarteten Fehlers enthalten.²²⁸ Hierfür werden insbesondere numerische Methoden genutzt.

Die Erforschung von modellgestützten Entscheidungstechniken für betriebliche Entscheidungsprozesse erfolgt seit Jahrzehnten im Rahmen des **Operations Research (OR)**.²²⁹ Diese interdisziplinäre Disziplin umfasst sowohl die Entwicklung von Methoden als auch deren IT-seitige Ausführung.²³⁰ Die Abgrenzung von OR in Bezug auf die Zuordnung einzelner Methoden wird in der Literatur unterschiedlich vorgenommen. Nach einer engen Definition umfasst diese Disziplin lediglich Methoden im Kontext von Entscheidungsmodellen; darüber hinaus wird OR aber auch als Oberbegriff für alle modellgestützten Verfahren verwendet, d. h. auch für Beschreibungs- und Erklärungsmodelle.

2.3.5.3 Abgrenzung zu datengestützten Entscheidungstechniken

Neben dem bisher vorherrschenden modellgestützten Ansatz zur Realisierung von Entscheidungstechniken, bei dem das Wissen zur Problemlösung durch den Menschen vorgegeben wird, existieren auch datengestützte Methoden, die entsprechend der in Kapitel 1.1 dargestellten Entwicklungen immer stärker an Bedeutung gewinnen. Bei diesen Methoden wird versucht, das benötigte Wissen aus Daten zur jeweiligen Entscheidungssituation zu extrahieren. Historisch werden hierzu v. a. klassische statistische Verfahren gezählt, wie sie bspw. bereits in den zuvor genannten Beschreibungs- und Prognosemodellen Anwendung finden – wobei in diesen Fällen oft weiterhin menschliches Wissen, z. B. in Form der Parametrisierung, eingebunden wird. Darüber hinaus bestehen aber auch komplexere, nicht-parametrisierte Methoden aus der Statistik und Mathematik. Diese kommen im Falle von ML zum Einsatz, weshalb diese Technologie auch als Vertreter der datengestützten Methoden zu betrachten ist.

Das Bindeglied zwischen daten- und modellgestützten Entscheidungstechniken – sowie damit auch zwischen den Disziplinen von OR und ML – stellt die Analytik bzw. **Analytics** dar (siehe Abbildung 16).²³¹ Diese sieht neben ML²³² auch den Einsatz klassischer statistischer Verfahren und modellgestützter Methoden vor und stellt daher eine Abkehr vom klassischen OR-Verständnis dar.²³³ Bei Analytics handelt es sich um eine eigene Disziplin, die seit Mitte der 2000er Jahren besteht und die Nutzung von großen Datenmengen – sowohl in strukturierter als auch

²²⁷ Vgl. Kahle (2001), S. 93; Pfohl (1977), S. 192

²²⁸ Vgl. Briskorn (2020), S. 10

²²⁹ Vgl. Koop, Moock (2018), S. 1

²³⁰ Vgl. Briskorn (2020), S. 2

²³¹ Vgl. Mortenson et al. (2015), S. 585

²³² ML wird mit der neu aufgenommenen und nunmehr letzten Analytics-Stufe in Form von „Autonomous Analytics“ assoziiert, welche die Autonomisierung von Entscheidungsprozessen umfasst. Vgl. Davenport, Harris (2017), S. 7 f.

²³³ Vgl. Das (2014), S. 7

in unstrukturierter Form – zur Unterstützung und Ausführung von Entscheidungsprozessen adressiert.²³⁴ Für den Unternehmenskontext wurde hierzu der Begriff der Geschäftsanalytik bzw. **Business Analytics** (BA) geprägt.²³⁵ Korrespondierend zu den drei Modellarten des modellgestützten Ansatzes lassen sich die im Kontext von Analytics realisierten Entscheidungstechniken hinsichtlich ihrer Funktionen in drei Stufen unterteilen: die Beschreibung von Problemen (Descriptive Analytics), die Ermittlung von tieferliegenden Zusammenhängen und von Prognosen (Diagnostic bzw. Predictive Analytics) sowie die Identifikation von Handlungsalternativen (Prescriptive Analytics).²³⁶




Abbildung 16: Abgrenzung von ML, Analytics und OR²³⁷

2.4 Machine Learning und Künstliche Intelligenz

Dieses Unterkapitel dient der Analyse und Abgrenzung der technischen Dimension des Untersuchungsfelds in Form der ML-Anwendungen. Dazu wird einleitend der übergeordnete Bereich der KI untersucht. Anschließend erfolgt eine Auseinandersetzung mit den Möglichkeiten zur Realisierung einer systemseitigen Lernfähigkeit als technische Grundlage für die Lösung von Problemen. Dazu werden mit der symbolischen und subsymbolischen KI bzw. den darauf basierenden systemtechnischen Realisierungsformen in Form der Expertensysteme und ML-Anwendungen die zwei zentralen Ansätze erläutert und abgegrenzt. Abschließend erfolgt eine detaillierte Betrachtung von ML durch die Herausarbeitung und Systematisierung wesentlicher Konzepte und Methoden.

2.4.1 Künstliche Intelligenz

Ausgehend von einer einleitenden Betrachtung der menschlichen Intelligenz, welche der späteren Modellierung von ML-Anwendungen dienen, wird in diesem Abschnitt die Forschungsdisziplin KI analysiert, wobei eine primär ingenieurwissenschaftliche Sicht mit Berücksichtigung kognitionswissenschaftlicher Zusammenhänge eingenommen wird. Neben einer Definition von KI werden die definitionsgemäßen Anforderungen an KI-Systeme erarbeitet, was auch mit der Darstellung verschiedener systemseitiger Fähigkeiten und anwendungsbezogener

²³⁴ Vgl. Davenport, Harris (2017), S. 6

²³⁵ Vgl. Holsapple et al. (2014), S. 131; Weber (2020), S. 6

²³⁶ Vgl. Davenport, Harris (2017), S. 7 f.

²³⁷ Eigene Darstellung in Anlehnung an Mortenson et al. (2015), S. 586

Teilbereiche einhergeht. Abschließend werden mit den KI-Hypothesen unterschiedliche technische Lösungsansätze beschrieben. Dies umfasst ebenfalls Aussagen zum aktuellen Stand und zu zukünftigen Szenarien.

2.4.1.1 Modellierung menschlicher Intelligenz

Die Grundlage für die Betrachtungen zu KI in der vorliegenden Arbeit stellt die menschliche **Intelligenz** dar, welche als „*Fähigkeit, abstrakt und vernünftig zu denken und daraus zweckvolles Handeln abzuleiten*“ beschrieben wird²³⁸. Im Zentrum dieser Definition steht demnach das Denken, welches – im Sinne einer Konkretisierung der resultierenden Handlungen – zur logischen Schlussfolgerung, zur Kreativität oder zur Problemlösung eingesetzt werden kann, wobei Letzteres auch als **problemlösendes Denken** bezeichnet wird.²³⁹ Zum Denken nutzt der Mensch verschiedene **kognitive Fähigkeiten**. Je nach Begriffsauffassung wird Denken dabei entweder als Oberbegriff im Sinne eines Ziels aller kognitiven Fähigkeiten (Denken i. w. S.) oder als eine dieser Fähigkeiten verstanden (Denken i. e. S.).²⁴⁰ Die individuellen Ausprägungen der kognitiven Fähigkeiten beim Menschen, welche durch verschiedene Testverfahren operationalisierbar sind, werden wiederum als Intelligenz verstanden.²⁴¹

Für die Darstellung und Abgrenzung dieser Fähigkeiten wird das Denken bzw. die Kognition in der Forschung als ein Prozess modelliert, bei dem der Mensch ein in die Umwelt eingebettetes **Informationsverarbeitungssystem** darstellt, welches Informationen aus der Umwelt aufnimmt, diese verarbeitet und die verarbeiteten Informationen wieder an die Umwelt zurückgibt (siehe Abbildung 17).²⁴² Während die Gedächtnisstrukturen des Menschen für die Transformation der Informationen zuständig sind, stellen seine Sinnesorgane und die Motorik die Schnittstellen zur Umwelt dar. Sowohl während der Verarbeitung als auch nach Ausgabe der Informationen finden Rückmeldungen aus der Umwelt statt, die zu einer Anpassung der Fähigkeiten führen können. Daher ist ein Modell des Denkens eher als ein Kreislauf zu betrachten, der auch als Wahrnehmungs-Handlungs-Zyklus (**Perception-Action Cycle** bzw. Loop) bezeichnet wird.²⁴³

²³⁸ Duden (2021)

²³⁹ Vgl. Funke (2003), S. 21 f.

²⁴⁰ Vgl. Hussy (1993), S. 42

²⁴¹ Vgl. Hussy (1984), S. 245

²⁴² Vgl. Hussy (1993), S. 42 f.

²⁴³ Vgl. Fuster (2005), S. 106 f.

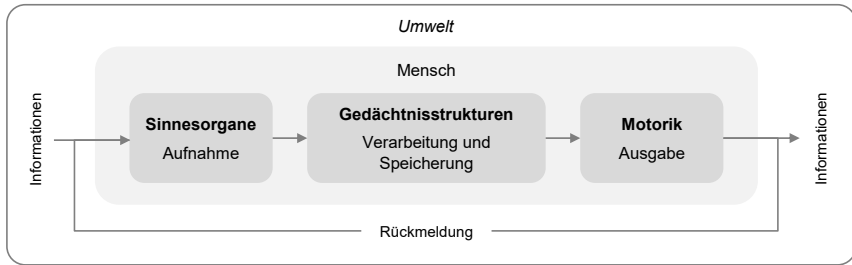


Abbildung 17: Menschliche Kognition als Informationsverarbeitungssystem²⁴⁴

Die Aufnahme von Informationen aus der Umwelt erfolgt mittels der kognitiven Fähigkeit der Wahrnehmung, wozu die menschlichen Sinnesorgane eingesetzt werden. Für die Bewertung, Filterung und Strukturierung der Information wird die Fähigkeit der Aufmerksamkeit genutzt.²⁴⁵ Die strukturierten Informationen werden anschließend im Rahmen des problemlösenden Denkens zu **Wissen** verarbeitet, welches alle Kenntnisse und Fähigkeiten eines Menschen zur Problemlösung umfasst.²⁴⁶ Der Wissensbegriff ist daher auch vom Informationsbegriff abzugrenzen, da Informationen erst auf geeignete Weise zur Problemlösung verarbeitet werden müssen. Der Erwerb von Wissen erfolgt durch die kognitive Fähigkeit des **Lernens**.²⁴⁷ Mittels des Kurz- und Langzeitgedächtnisses werden die Information und das erworbene Wissen gespeichert.²⁴⁸ Die Ausgabe der verarbeiteten Informationen in Form von Problemlösungen erfolgt mittels der Sprache, wozu der Mensch auf die Fähigkeit der Verbalisierung zurückgreift, und/oder durch die Bewegungsfunktionen des Körpers in Form der motorischen Fähigkeiten.

2.4.1.2 Wissenschaftstheoretische Einordnung und Definition von KI

Seit der industriellen Revolution verfolgen Menschen das Ziel einer Automatisierung, d. h. einer „*Delegation von Tätigkeiten an Maschinen, die in der Lage sind, diese selbsttätig auszuführen*“²⁴⁹. Ausgehend von der damit verbundenen Substitution motorischer Fähigkeiten hat sich mit dem Aufkommen der Informationstechnik der Gedanke der **Automatisierung auf kognitive Fähigkeiten** des Menschen erweitert.²⁵⁰ Damit einher ging das Ziel zur Entwicklung von Maschinen bzw. IT-Systemen²⁵¹, welche Tätigkeiten übernehmen können, für die der Mensch Intelligenz benötigt. Die ersten umfassenden Überlegungen dazu wurden durch *Turing (1950)* formuliert, dessen Arbeit heute als Ursprung der KI-Forschung gilt.

²⁴⁴ Eigene Darstellung in Anlehnung an Hussy (1993), S. 43; Fuster (2005), S. 109

²⁴⁵ Vgl. Hussy (1993), S. 57 f.

²⁴⁶ Vgl. Thommen et al. (2017), S. 552

²⁴⁷ Vgl. Hussy (1984), S. 203

²⁴⁸ Vgl. Hussy (1984), S. 183 ff.

²⁴⁹ Heßler (2019), S. 235

²⁵⁰ Vgl. Russell, Norvig (2012), S. 39 f.; Mainzer (2018), S. 9

²⁵¹ Im weiteren Verlauf wird für alle Artefakte auf Basis von KI der Begriff des Systems verwendet.

Aus der Historie von KI sind verschiedene Forschungsansätze hervorgegangen, die teilweise in Konkurrenz zueinanderstanden, sich aber auch positiv beeinflusst haben.²⁵² In Bezug auf die übergeordnete Zielsetzung können drei Gruppen von Aktivitäten festgestellt werden. Die erste Gruppe strebt nach einem Verständnis der menschlichen Intelligenz, um darauf basierend das menschliche Denken und Handeln systemseitig nachzubilden, was auch als kognitive Modellierung bezeichnet wird²⁵³. Die zweite Gruppe fokussiert die Entwicklung von Systemen zur Lösung von Anwendungsproblemen, indem bestehende Konzepte und Methoden angewendet und erprobt werden. Die dritte Gruppe legt den Schwerpunkt auf die Entwicklung dieser methodischen Grundlage, indem u. a. neue Algorithmen entworfen werden. Während die erste Gruppe insbesondere der Disziplin der Kognitionswissenschaft zuzuordnen ist, entstammen die Arbeiten der zweiten und dritten Gruppe der Informatik und damit den Ingenieurwissenschaften, wobei der Schwerpunkt der dritten Gruppe in der theoretischen Informatik und der Mathematik liegt. Entsprechend dieses inhaltlichen Spektrums bildet KI eine interdisziplinäre Forschungsdisziplin mit **ingenieurs- und kognitionswissenschaftlichen Zielsetzungen** (siehe Abbildung 18). In der vorliegenden Arbeit stehen die ingenieurwissenschaftlichen Fragestellungen von KI im Sinne der zweiten anwendungsorientierten Gruppe im Fokus.




Abbildung 18: Einordnung von KI in Wissenschaftsdisziplinen²⁵⁴

Analog zu den vielfältigen Forschungsaktivitäten existiert auch eine Vielzahl von Definitionen von KI.²⁵⁵ Im Sinne der eigenommenen anwendungsorientierten Perspektive der Arbeit wird die Definition von *Rich (1983)* herangezogen, nach der KI wie folgt beschrieben wird:

*„Artificial intelligence (A.I.) is the study of how to make computers do things that people are better at.“*²⁵⁶

KI umfasst demnach alle Aktivitäten zur Erstellung von computergestützten Systemen, die für Aufgaben entwickelt wurden, in denen – aktuell – der Mensch besser ist. *Rich (1983)* bezieht sich im weiteren Verlauf der entsprechenden Veröffentlichung auf die Umsetzung kognitiver Fähigkeiten, wobei sie u. a. die Wahrnehmung und die Problemlösung als Beispiele nennt. Auch verweist sie auf einen perspektivischen Leistungsvorsprung der KI-Systeme gegenüber dem Menschen. Für eine weitere Detaillierung des Verständnisses zu KI in Hinblick auf die

²⁵² Vgl. Russell, Norvig (2012), S. 22 ff.

²⁵³ Vgl. Hussy (1984), S. 23; Franklin (2014), S. 30

²⁵⁴ Eigene Darstellung in Anlehnung an Wahlster (2001), S. 2

²⁵⁵ Ein Überblick findet sich in Wahlster, Winterhalter (2020), S. 36 f.

²⁵⁶ Rich (1985), S. 117 zitiert nach Rich (1983)

resultierenden Systeme wird zusätzlich die Definition der Europäischen Kommission zu KI angeführt. Nach dieser nehmen KI-Systeme Informationen aus der Umwelt wahr und leiten daraus geeignete Aktionen ab, wobei sie zum Erreichen ihrer Ziele in einem gewissen Maße eigenständig agieren. Sie können dabei entweder als reine Softwaresysteme oder zusammen mit hardwareseitigen Komponenten, z. B. in Form autonomer Fahrzeuge oder Roboter, realisiert werden²⁵⁷:

*„Artificial intelligence (AI) refers to systems that display intelligent behaviour by analysing their environment and taking actions – with some degree of autonomy – to achieve specific goals. AI-based systems can be purely software-based, acting in the virtual world [...] or AI can be embedded in hardware devices [...].“*²⁵⁸

2.4.1.3 Fähigkeiten und Teilbereiche von KI

Im Rahmen der genannten Definitionen wird nicht einheitlich und abschließend determiniert, welche Fähigkeiten ein System aufweisen muss, damit es als „künstlich intelligent“ bezeichnet werden kann. Ein anerkannter Ansatz zur Qualifizierung dieses Wesensmerkmals stellt der **Turing-Test** dar, welcher der bereits angesprochenen Arbeit von *Turing (1950)* entstammt und vier Fähigkeiten von intelligenten Systemen einfordert. Dieser Test wurde später um die zwei Fähigkeiten der Wahrnehmung und Handlung von *Harnad (1991)* zum totalen Turing-Test erweitert. Bei diesen technischen Fähigkeiten, welche gleichzeitig die definitionsgemäßen Eigenschaften einer künstlichen Intelligenz darstellen (siehe Tabelle 3), erfolgt eine Orientierung an den in Kapitel 2.4.1.1 dargestellten kognitiven und motorischen Fähigkeiten des Menschen. Diese umfassen das Erfassen und Verstehen von Informationen durch das Sehen, Tasten und Erkennen von Sprache, den kontinuierlichen **Erwerb von Wissen in Form eines maschinellen Lernens**, die Speicherung dieses Wissens und das Ziehen darauf basierender Schlussfolgerungen sowie die Ausübung entsprechender Handlungen in Form von Manipulationen und der Sprache.²⁵⁹ Das Prinzip des Turing-Tests sieht eine Situation vor, in der ein Mensch mit einem System im Rahmen einer Unterhaltung und einer Übergabe von Objekten interagiert. Sollte der Mensch nicht erkennen, dass es sich bei seinem Gegenüber um ein System handelt, gilt der Test als bestanden und das System als intelligent. Dazu muss dieses über alle zuvor beschriebenen Fähigkeiten verfügen.

²⁵⁷ Dies Realisierungsform bezieht sich auf das primäre Erscheinungsbild der Systeme. Wie die Ausführungen in Kapitel 2.1 zeigen, werden auch zur Ausführung von Software Hardwarekomponenten benötigt.

²⁵⁸ Europäische Kommission (2018), S. 1

²⁵⁹ Vgl. Russell, Norvig (2012), S. 23 f.

Eigenschaft des Systems	Beschreibung	Korrespondierende menschliche Fähigkeit
Verarbeitung natürlicher Sprache (Natural Language Processing)	Kommunikation in der jeweiligen Sprache	Sprache verstehen und sprechen
Wissensrepräsentation (Knowledge Representation)	Speicherung und Organisation von Wissen	Merken und erinnern
Logisches Schließen bzw. Inferenz (Reasoning)	Schlussfolgerungen auf Basis von Wissen	Treffen rationaler Entscheidungen
Maschinelles Lernen (Machine Learning)	Erwerb von (neuem) Wissen	Lernen
Maschinelles Sehen (Computer Vision)	Wahrnehmung von Objekten	Sehen
Robotik (Robotics)	Manipulation von Objekten	Bewegen (Motorik)

Tabelle 3: Eigenschaften von intelligenten Systemen im Sinne des totalen Turing-Tests

Die gezielte Entwicklung von definitionsgemäßen intelligenten Systemen, welche alle angesprochenen Fähigkeiten vereinen, stand bisher nicht im Fokus der KI-Forschung. Stattdessen wurden vordergründig Lösungen zur technischen Realisierung einzelner Fähigkeiten entwickelt.²⁶⁰ Anhand der damit verbundenen Aktivitäten lassen sich bestimmte Schwerpunkte der anwendungsorientierten KI-Forschung ableiten, die u. a. als Technologien oder **Forschungsbereiche** von KI bezeichnet werden und nachfolgend prägnant beschrieben sind.²⁶¹ Zwischen den einzelnen Bereichen bestehen große inhaltliche Schnittmengen. Insbesondere ML und Expertensysteme werden aufgrund ihrer Fähigkeit zur Problemlösung in allen anderen Teilbereichen eingesetzt. Entsprechend ihrer Bedeutung für die vorliegende Arbeit werden diese beiden Bereiche im Kapitel 2.4.2 detailliert betrachtet.

Im Bereich des **Natural Language Processing (NLP)** werden Lösungen zur systemseitigen Verarbeitung von natürlicher Sprache entwickelt. Dazu erfolgt eine Erkennung der jeweiligen Sprache, was auch als **Speech Recognition** bezeichnet wird, sowie deren Umwandlung und Interpretation. Die resultierenden Informationen werden zur Ausführung von Aktionen, z. B. im Rahmen von Geschäftsprozessen oder zur Interaktion mit dem Menschen genutzt. Letztes erfolgt durch die Ausgabe mittels Dialogsystemen, die entweder visuell via Chatbots oder akustisch in Form von Sprachassistenten kommunizieren. Zusätzlich zur gesprochenen Sprache wird auch mitunter die Verarbeitung von Sprache in Form von Texten, d. h. die **Optical Character Recognition**, dem NLP-Bereich zugeordnet.

Der Bereich des **Computer Vision** adressiert Lösungen zur visuellen Erkennung der Umwelt. Dazu werden Bilder oder Videos, die u. a. mittels Kamerasystemen oder optischen Sensoren

²⁶⁰ Vgl. Frankish, Ramsey (2014), S. 5

²⁶¹ In der Literatur variieren die Systematisierung und Benennung der KI-Teilbereiche. Die hier vorgenommene Abgrenzung und Beschreibung orientieren sich an Seifert et al. (2018), S. 15; Weber (2020), S. 37 ff.; Franklin (2014), S. 24 ff.

aufgenommen wurden, verarbeitet und nach Merkmalen analysiert. Durch die darauf basierende Interpretation der entsprechenden Inhalte können Objekte und Situationen erkannt werden. Diese werden für eine Weiterverarbeitung oder Ausgabe an den Menschen genutzt, um u. a. auf Störungen hinzuweisen, wie im Falle von Fahrassistenzsystemen. Im industriellen Kontext wird dieser Bereich auch als **Machine Vision** bezeichnet und dient u. a. einer Überwachung von Prozessen.

Der Bereich der **Robotik** dient der Entwicklung von Robotern, welche zur Manipulation von Objekten eingesetzt werden. Die damit verbundenen Aktivitäten werden historisch eher dem Maschinenbau und der Elektrotechnik zugeordnet. Durch eine vermehrte Nutzung von Lösungen aus den anderen KI-Bereichen, u. a. zur visuellen und akustischen Wahrnehmung der Umwelt sowie zur eigenständigen Anpassung von Handlungen, werden diese Aktivitäten jedoch mittlerweile auch als ein eigenständiger Bereich von KI geführt. Auf Grundlage des originären Gedankens der Verrichtung ausführender Tätigkeiten hat sich mit dem **Robot Process Automation (RPA)** ein separater Teilbereich herausgebildet, der die Entwicklung von roboterähnlichen Systemen in Form von Software zur Ausführung von Informationsprozessen im Unternehmenskontext, v. a. von repetitiven Aufgaben, adressiert.

Im Bereich der wissensbasierten Systeme (Knowledge-based Systems) bzw. **Expertensysteme** (Expert Systems) werden Lösungen zur Nutzung des menschlichen Wissens für die Lösung von Problemen in einer spezifischen Domäne entwickelt. Das jeweilige Wissen wird dazu in geeigneter Weise gespeichert und repräsentiert, um auf dieser Grundlage eine Schlussfolgerung durch die Systeme zu ermöglichen. Dieser Bereich umfasst damit insbesondere eine Realisierung der beiden KI-Fähigkeiten der **Knowledge Representation** und des **Reasoning**. Mitunter werden diese auch als separate Bereiche geführt.

Der Bereich des **Machine Learning** umfasst die Entwicklung von Lösungen zur Realisierung einer systemseitigen Lernfähigkeit, wozu Daten für den jeweiligen Anwendungsbereich genutzt werden. Hierdurch werden Systeme befähigt, eigenständig Wissen für Problemlösungen zu erwerben und dieses kontinuierlich zu verbessern.

2.4.1.4 KI-Hypothesen (schwache und starke KI)

Mit dem Beginn der KI-Forschung wurden Bestrebungen zur Entwicklung einer dem Menschen ebenbürtigen Intelligenz, d. h. einer **Human-level Intelligence**²⁶², formuliert. Im weiteren Verlauf der Forschung musste jedoch festgestellt werden, dass diese unter den vorherrschenden technischen Bedingungen nicht realisierbar ist. Daher wurde im Rahmen der einzelnen KI-Bereiche dazu übergangen, problembezogene Systeme zu entwickeln, die nur in der Lage sind, ihre Fähigkeiten für den vorgesehenen Anwendungsfall auf geeignete Weise einzusetzen.²⁶³ Von einer menschenähnlichen Intelligenz kann bei diesen Systemen daher nicht gesprochen werden. Vielmehr handelt es sich um eine „Simulation“ des Denkens in Bezug auf

²⁶² Vgl. Bostrom, Yudkowsky (2014), S. 318

²⁶³ Vgl. Franklin (2014), S. 16

den jeweiligen Anwendungsfall, sodass mitunter auch von intelligent *agierenden* Systemen gesprochen wird.²⁶⁴ Für diesen Realisierungsansatz wurde allgemein der Begriff der **schwachen KI-Hypothese** bzw. der schwachen KI („Weak AI“) geprägt.²⁶⁵ Alle gegenwärtigen KI-Systeme werden dieser KI-Hypothese zugeordnet. Anders als es jedoch die Semantik des Begriffes vermuten lässt, zeigen heutige KI-Anwendungen in vielen Bereichen bereits einen **Leistungsvorsprung gegenüber dem Menschen**. Als Beispiele können Systeme für die Erkennung von Bildern (Computer Vision) und Sprache (NLP) angeführt werden, die seit mehreren Jahren nachweisbar bessere Ergebnisse gegenüber dem Menschen erzielen – mit einer steigenden Tendenz zugunsten der Systeme.²⁶⁶ Auch konnten in den letzten Jahren mehrere medienwirksame Erfolge verzeichnet werden. Hierzu zählen z. B. die auf ML basierenden Systeme „AlphaGo“ und „AlphaGo Zero“, welche im Brettspiel „Go“ die weltweit führenden menschlichen Spieler besiegten.²⁶⁷ Entsprechend dieser bereits realisierten partiellen Überlegenheit von KI-Systemen wird anstelle einer schwachen KI auch häufig der passendere Begriff der **Narrow AI** genutzt.²⁶⁸

Auch wenn bislang noch keine darüberhinausgehenden Vertreter existieren, wurden bereits verschiedene technische Ansätze und Visionen zu zukünftigen KI-Systemen entwickelt. Grundlage dieser Betrachtungen bildet die **starke KI-Hypothese** bzw. starke KI („Strong AI“), welche als ein technischer Gegenentwurf zur schwachen Hypothese zu verstehen ist. Ihr liegt die Annahme zugrunde, dass KI-Systeme wortwörtlich selbst denken sollen, d. h. ihre Aufgabe verstehen und über kognitive Zustände verfügen.²⁶⁹ Durch die damit verbundene Realisierung einer menschenähnlichen Intelligenz sollen die entsprechenden Systeme flexibel und kontextübergreifend agieren, sodass sie über den vorgesehenen Anwendungsbereich hinweg, einschließlich unbekannter Probleme, geeignete Lösungsmöglichkeiten ermitteln können.²⁷⁰ Damit gehen auch weitere systemseitige Fähigkeiten einher, wie die Kreativität und die Generierung von Wertentscheidungen. Auch das Vorhandensein eines **Bewusstseins**, d. h. einer bewusst erlebten Innenperspektive der Systeme, sowie von Emotionen wird im Kontext dieser Hypothese diskutiert. Zur Entwicklung entsprechender Systeme soll die Funktionsweise des menschlichen Gehirns und dessen Fähigkeiten nachgebildet werden, was als Reverse Engineering bezeichnet wird.²⁷¹ Diese reine Nachahmung des Menschen wird u. a. durch das Konzept der Human-Level AI repräsentiert.²⁷² Demgegenüber stehen aktuelle Konzepte, wie

²⁶⁴ Vgl. Weinberger et al. (1994), S. 3

²⁶⁵ Vgl. Searle (1980), S. 417

²⁶⁶ Vgl. Zhang et al. (2021), S. 47, 62 f.

²⁶⁷ Beide Systeme wurden durch DeepMind Technologies, ein Tochterunternehmen von Google bzw. Alphabet Inc., entwickelt. Vgl. Silver et al. (2017), S. 354 ff.

²⁶⁸ Vgl. Kurzweil (2005), S. 206

²⁶⁹ Vgl. Searle (1980), S. 417

²⁷⁰ Vgl. Kurzweil (2005), S. 222

²⁷¹ Vgl. Kurzweil (2005), S. 205

²⁷² Vgl. Nilsson (2010), S. 645

die **Artificial General Intelligence** (AGI), welche auch von den menschlichen Voraussetzungen abweichende Realisierungsmöglichkeiten berücksichtigt.²⁷³ Im Zuge der sich stetig verbessernden technischen Möglichkeiten wird die Realisierung einer AGI mittlerweile als ein wichtiger Trend innerhalb der KI-Forschung betrachtet.²⁷⁴

Für die potenzielle Realisierung von Systemen im Kontext der starken KI-Hypothese werden in der Zukunftsforschung verschiedene Sichtweisen eingenommen. Während teilweise von einer grundlegenden Unmöglichkeit ausgegangen wird, geben mehrere Studien als Realisierungszeitraum für das Erreichen einer menschenebenen Intelligenz die 2040er bis 2050er Jahre mit einer 50-prozentigen und die 2070er bis 2090er Jahre mit einer 90-prozentigen Wahrscheinlichkeit an.²⁷⁵ Aufgrund der Fortschritte beim Verständnis der Funktionsweise des Gehirns und bei dessen systemseitiger Überführung wird teilweise aber auch angeführt, dass sich die Forschung bereits auf dem Weg zur starken KI befindet.²⁷⁶

Als eine Steigerung des AGI-Konzeptes kann das bereits in den 1960er Jahren von *Good* (1966) entworfene und u. a. von *Bostrom* (2014) weiterentwickelte Konzept der **Superintelligenz** angesehen werden, welches von KI-Systemen ausgeht, die dem Menschen in allen Aufgaben – mitunter deutlich – überlegen sind. Hierbei kann es sich u. a. um höhere Geschwindigkeiten bei der Bewältigung der Aufgaben oder um das Vorhandensein von Fähigkeiten handeln, über die der Mensch nicht verfügt.²⁷⁷ Diesem Zukunftskonzept liegt der technische Ansatz zugrunde, dass die vom Menschen entwickelten KI-Systeme selbst in der Lage sind, neue und noch intelligenteren Systeme zu entwerfen (sog. Intelligenzexplosion).²⁷⁸ Für eine Realisierbarkeit der Superintelligenz und dessen Zeitpunkt können jedoch aktuell keine belastbaren Aussagen getätigt werden. In der Forschung werden aber bereits mögliche Auswirkungen betrachtet.²⁷⁹ Diese **Zukunftsszenarien** reichen von hohen gesellschaftlichen und betrieblichen Mehrwerten bis hin zu apokalyptischen Visionen. Trotz der Unsicherheit über die Realisierbarkeit der entsprechenden Systeme können diese Szenarien bereits jetzt Einfluss auf die Akzeptanz von KI und damit assoziierten Technologien in Unternehmen nehmen.

2.4.2 Lernende Systeme

Für den erfolgreichen Einsatz von KI-Systemen zur Übernahme von kognitiven Aufgaben müssen diese in der Lage sein, bisher unbekannte Probleme zu lösen, wobei dies in der betrieblichen Praxis auch für eine ausgeprägte Komplexität der jeweiligen Probleme gelten muss. Das Lösen von Problemen setzt im Sinne der gegenwärtig zutreffenden KI-Hypothese bei den Sys-

²⁷³ Vgl. Goertzel (2007), S. 1163

²⁷⁴ Vgl. Franklin (2014), S. 30

²⁷⁵ Vgl. Bostrom (2014), S. 20 f.

²⁷⁶ Vgl. Kurzweil (2005), S. 222

²⁷⁷ Vgl. Mainzer (2018), S. 222 f.

²⁷⁸ Vgl. Good (1966), S. 33

²⁷⁹ Vgl. Goertzel (2007), S. 1164 ff.

temen dedizierte Kenntnisse und Fähigkeiten zum jeweiligen Anwendungsbereich, d. h. Wissen, voraus, welches auf Basis von empirischen Informationen aus der Umwelt erworben werden muss.²⁸⁰ In Analogie zum Menschen wird diese Fähigkeit auch im Kontext von Systemen als **Lernen** bezeichnet, für dessen technische Realisierung grundsätzlich mehrere Möglichkeiten zur Verfügung stehen.²⁸¹

Mit der **symbolischen KI** und der **subsymbolischen KI** haben sich in der Forschung zwei zentrale Ansätze herausgebildet²⁸², welche aufgrund ihres jeweiligen Potenzials zur Lösung von Problemen auch mitunter als Paradigmen von KI bezeichnet werden. Zu den populärsten systemtechnischen Realisierungsformen dieser Ansätze gehören **Expertensysteme** (symbolische KI) und **ML-Anwendungen** (subsymbolische KI). Zur Herausstellung der besonderen Eigenschaften von ML und der Ableitung eines eindeutigen Begriffsverständnisses zur systemseitigen Lernfähigkeit werden beide Ansätze in diesem Abschnitt beschrieben und abschließend gegenübergestellt.

2.4.2.1 Grundlagen einer systemseitigen Lernfähigkeit

Für die technische Realisierung einer systemseitigen Lernfähigkeit bedarf es neben dem Erwerb des Wissens für die Problemlösung auch dessen Organisation, Speicherung und Verarbeitung, sodass diese Vorgänge als integraler Bestandteil des systemseitigen Lernprozesses betrachtet werden.²⁸³ Nachfolgend werden die Vorgänge mit ihren Ausprägungsformen beschrieben, wobei diese im Falle der subsymbolischen KI nur aus theoretischer Sicht voneinander abgrenzbar sind.

Der **Erwerb von Wissen** umfasst die gezielte Nutzung von neuen Informationen zur Überführung in Kenntnisse und Fähigkeiten, die zur Problemlösung benötigt werden. Dieser zentrale Vorgang des Lernprozesses kann grundsätzlich manuell oder automatisch erfolgen. Beim **manuellen Wissenserwerb** wird das notwendige Wissen durch den Menschen an das System übergeben, d. h. durch ihn programmiert. Beim **automatischen Wissenserwerb** wird das System stattdessen dazu befähigt, sich das Wissen selbständig anzueignen.²⁸⁴ Dazu werden dem System Einzelfälle sowie optional weiteres Vorwissen (apriorisches Wissen) übergeben, anhand dessen es eigenständig die Regeln zur Problemlösung ableitet und diese ebenfalls eigenständig modelliert. Die nachfolgenden Vorgänge der Speicherung und Organisation sowie der Verarbeitung laufen daher in diesem Fall integriert mit dem Wissenserwerb ab.

In Bezug auf die **Speicherung und Organisation von Wissen** bedarf es dessen geeigneter systemseitiger Modellierung. Hierzu existieren in der KI-Forschung zwei Möglichkeiten, die namensgebend für die KI-Paradigmen sind. Bei der **symbolischen Modellierung** wird das

²⁸⁰ Vgl. Russell, Norvig (2012), S. 65

²⁸¹ Übersichten zu unterschiedlichen Systematisierungen der Lernfähigkeit von Systemen finden sich in Dillmann (1988), S. 26 ff.; Carbonell et al. (1983), S. 7 ff.; Weinberger et al. (1994), 16 ff.

²⁸² Vgl. Wahlster (2017), S. 41 f.; Russell, Norvig (2012), S. 48 f.; Carbonell et al. (1983), S. 6

²⁸³ Vgl. Weinberger et al. (1994), S. 3

²⁸⁴ Vgl. Weinberger et al. (1994), S. 11

Wissen in eine symbolische Form überführt, z. B. mittels Logiken, Wissensgraphen, semantischen Netzwerken und Ontologien.²⁸⁵ Bei der **subsymbolischen Modellierung** von Wissen wird dieses verteilt gespeichert und organisiert. Demnach existieren in diesen Modellen viele informationsverarbeitende Elemente, welche in einem dichten Netzwerk miteinander verbunden sind, interagieren und sich gegenseitig beeinflussen.²⁸⁶ Entsprechend der Verbindungen zwischen den einzelnen Elementen wird dieser Ansatz auch als **Konnektionismus** bezeichnet.²⁸⁷ Im Vergleich zur symbolischen Modellierung findet beim subsymbolischen Ansatz eine stärkere Orientierung an biologischen Prozessen statt, die mitunter zu einer komplexen und schwer durch den Menschen interpretierbaren Struktur führt.²⁸⁸ Einen wichtigen methodischen Ansatz in diesem Zusammenhang stellen Neuronale Netze (NN) dar, deren Funktionsweise sich am menschlichen Gehirn orientiert. Die Gesamtheit des gespeicherten Wissens wird auch als Wissensbasis der Systeme bezeichnet.²⁸⁹

Unter der **Verarbeitung von Wissen** werden verschiedene Vorgänge subsumiert, wozu insbesondere die systemseitige Ermittlung geeigneter Problemlösungen (Entscheidungen) zählt, was als **Schlussfolgerung bzw. Inferenz** bezeichnet wird. Für die Inferenz existieren mit den sog. logischen Schlüssen drei Ausprägungen.²⁹⁰ Bei der **Deduktion** wird allgemein von einer bereits bekannten Regel oder Prämisse und einem übergebenen Einzelfall auf ein Ergebnis geschlossen. Es wird dazu von dem jeweiligen System für den Einzelfall geprüft, ob in dem vorhandenen Wissen ein zutreffender allgemeiner Zusammenhang gefunden werden kann, der aufgrund der Beschreibungen des Einzelfalls anwendbar ist. Bei der **Abduktion** wird von einer bekannten Regel und einem übergebenen Ergebnis auf einen Einzelfall geschlossen. Es wird versucht, für ein beobachtetes Phänomen eine Hypothese zu bilden. Somit wird diese Art der Inferenz auch als „kreativer Schluss“ bezeichnet. Ein Nachteil der Deduktion und Abduktion ist, dass für eine geeignete Problemlösung ein möglichst vollständiges und konsistentes Wissen in Form der Regeln über den Anwendungsbereich vorhanden sein muss. Das Gegenstück zur Deduktion stellt die **Induktion** dar, bei der von einem bekannten Ergebnis und einem übergebenen Einzelfall auf eine Regel geschlossen wird. Es handelt sich hierbei um eine Generalisierung, indem Eigenschaften eines oder oft mehrerer Einzelfälle und ggf. weiterer Hintergrundinformationen auf die Gesamtheit angewandt werden. Damit unterliegen die Ergebnisse der Inferenz stets einer Wahrscheinlichkeit.

In Bezug auf die einzelnen Vorgänge zur Realisierung einer systemseitigen Lernfähigkeit lassen sich zusammenfassend für die beiden KI-Paradigmen bzw. die darauf basierenden Systeme typische Ausprägungen ableiten. Diese sind in Tabelle 4 dargestellt und werden in den nachfolgenden Abschnitten erläutert.

²⁸⁵ Vgl. Wahlster, Winterhalter (2020), S. 43; Russell, Norvig (2012), S. 518 ff.

²⁸⁶ Vgl. Weinberger et al. (1994), S. 98

²⁸⁷ Vgl. Franklin (2014), S. 15; Funke (2003), S. 90

²⁸⁸ Vgl. Carbonell et al. (1983), S. 6

²⁸⁹ Vgl. Dillmann (1988), S. 24 f.

²⁹⁰ Vgl. hierzu und zu diesem Abschnitt Reichertz (2016), S. 129 ff.

Lernprozess	Ausprägung	Symbolische KI (Expertensysteme)	Subsymbolische KI (ML-Anwendungen)
Wissenserwerb (Lernen im engeren Sinne)	Manuell	x	
	Automatisch		x
Wissensorganisation und -speicherung (Wissensmodellierung)	Symbolisch	x	x
	Konnektionistisch		x
Wissensverarbeitung (Inferenz)	Deduktiv	x	(x) ²⁹¹
	Induktiv		x

Tabelle 4: Typische Merkmalsausprägungen der KI-Paradigmen beim Lernprozess

2.4.2.2 Expertensysteme (symbolische KI)

Expertensysteme bzw. die übergeordneten wissensbasierten Systeme stellen die bisher populärste Realisierungsform der symbolischen KI dar. Das Wissen dieser Systeme zur Lösung von Problemen wird exklusiv von Menschen übergeben, wobei es sich häufig um Expertenwissen zum jeweiligen Anwendungsbereich handelt. Daher wird in diesen Fällen auch die Bezeichnung der Expertensysteme verwendet.²⁹² Ziel der Systeme ist es, für einen „gegebenen Spezialisierungsbereich menschliche Experten in Bezug auf ihr Wissen und ihre Schlussfolgerungsfähigkeit“ bestmöglich nachzubilden.²⁹³ Dazu wird das Wissen mittels **symbolischer Modellierungsformen** gespeichert, die eine eindeutige Zuordnung zwischen den Informationen und die Möglichkeit eines logischen Schlusses erlauben.²⁹⁴

Das technische Prinzip der Systeme sieht eine Trennung des Wissens über den Anwendungsbereich (sog. Wissenselement) von der anwendungsunabhängigen Wissensverarbeitung (sog. Inferenzelement) vor. Erst im Falle einer benötigten Problemlösung werden beide Elemente miteinander verbunden, wozu Regeln oder Ontologien – oftmals in Form von Wenn-Dann-Beziehungen – implementiert werden.²⁹⁵ Daher wird in diesem Kontext auch von **regelbasierten Systemen** gesprochen.²⁹⁶ Auf Grundlage des vorgegebenen Wissens sind die Systeme in der Lage, einen übergebenen Einzelfall anhand von Kriterien zu bewerten und den verfügbaren Regeln für eine geeignete Problemlösung zuzuordnen. Es handelt sich dabei um einen **deduktiven Schluss**, dessen Ergebnisse wiederum an das System zurückgeführt werden können, wobei jedoch keine automatische Anpassung des Wissens erfolgt.

²⁹¹ Der Wissenserwerb auf Basis von Einzelfällen entspricht einer induktiven Inferenz. Bei der Nutzung dieses Wissens für die Lösung neuer Fälle handelt es sich um eine Deduktion.

²⁹² Vgl. Puppe (1990), S. 2

²⁹³ Beierle, Kern-Isberner (2019), S. 12

²⁹⁴ Vgl. Carbonell et al. (1983), S. 6

²⁹⁵ Vgl. Beierle, Kern-Isberner (2019), S. 11

²⁹⁶ Vgl. Funke (2003), S. 88 f.

2.4.2.3 Machine Learning (subsymbolische KI)

Mit dem subsymbolischen Ansatz wurde bereits in den 1950er Jahren eine Alternative zur symbolischen KI formuliert, welche eine Befähigung von Systemen zum eigenständigen Erwerb des benötigten Wissens zur Problemlösung vorsah. *Samuel (1959)* hat für diesen Ansatz den Begriff des **Maschinellen Lernens bzw. Machine Learning** geprägt, welcher wie folgt definiert wird:

„A computer program is said to learn from experience E with respect to some class of tasks T and performance measure P , if its performance at tasks in T , as measured by P , improves with experience E .“²⁹⁷

Entsprechend dieser Definition findet das Lernen eines Systems auf Grundlage von systemseitigen Erfahrungen (E). Hierbei handelt es sich um Zusammenhänge, die das System anhand von übergebenen Daten, welche Einzelfälle und ggf. weitere Informationen zu dem jeweiligen problembezogenen Anwendungsbereich enthalten, ermittelt hat. Im Sinne einer **induktiven Inferenz** werden diese Beobachtungen zu einem Wissen generalisiert und für die Lösung von neuen, unbekanntem Fällen (T) eingesetzt. Die jeweils resultierenden Ergebnisse werden anschließend anhand einer vorgegebenen Leistungsmetrik (P) bewertet. Im Falle von Abweichungen passt das System sein Verhalten, d. h. sein Wissen, automatisch an. Dieser Lernprozess wird solange ausgeführt, bis das Problem entsprechend der vorgegebenen Leistungsmetrik gelöst ist. Zur Realisierung des Lernens im Kontext von ML werden mathematisch-statistische Methoden (sog. **Lernverfahren**) eingesetzt, welche das benötigte Wissen aus Daten extrahieren.²⁹⁸ Ursprünglich gehören hierzu v. a. Verfahren, bei denen das Wissen **konnektionistisch** modelliert ist, wie z. B. bei NN. Nach gegenwärtiger Auffassung werden aber auch Verfahren mit ML assoziiert, die eine **symbolische Wissensmodellierung** aufweisen, wie z. B. Entscheidungsbäume oder evolutionäre Algorithmen.²⁹⁹ Trotz der damit semantisch nicht in allen Fällen zutreffenden Bezeichnung findet in der Literatur zumeist eine Gleichsetzung von ML mit der subsymbolischen KI statt.³⁰⁰

Die Realisierung einer systemseitigen Lernfähigkeit auf Grundlage der zuvor dargelegten Definition von ML findet in mehreren eng miteinander verbundenen Vorgängen innerhalb des jeweiligen IT-Systems statt. Diese „maschinell lernenden“ Systeme werden in der vorliegenden Arbeit als **Lernende Systeme** oder **ML-Anwendungen** bezeichnet.³⁰¹ Ihr grundsätzliches Funktionsprinzip ist unter Nutzung des in Kapitel 2.4.1.1 eingeführten Verständnisses vom menschlichen Denken als ein Informationsverarbeitungssystem³⁰² in Abbildung 19 modelliert und wird nachfolgend beschrieben.

²⁹⁷ Mitchell (1997), S. 2

²⁹⁸ Eine weiterführende Erklärung der Lernverfahren von ML erfolgt in Kapitel 2.4.3.2.

²⁹⁹ Vgl. Weinberger et al. (1994), S. 26

³⁰⁰ Vgl. Marsland (2015), S. 4

³⁰¹ Eine Definition der beiden Begriffe erfolgt im nachfolgenden Abschnitt.

³⁰² Zur Beschreibung von Systemen auf Basis von ML bzw. KI werden diese in Analogie zum Menschen häufig auch als Agentenprogramme modelliert. Vgl. Russell, Norvig (2012), S. 60 ff. Ein Agent

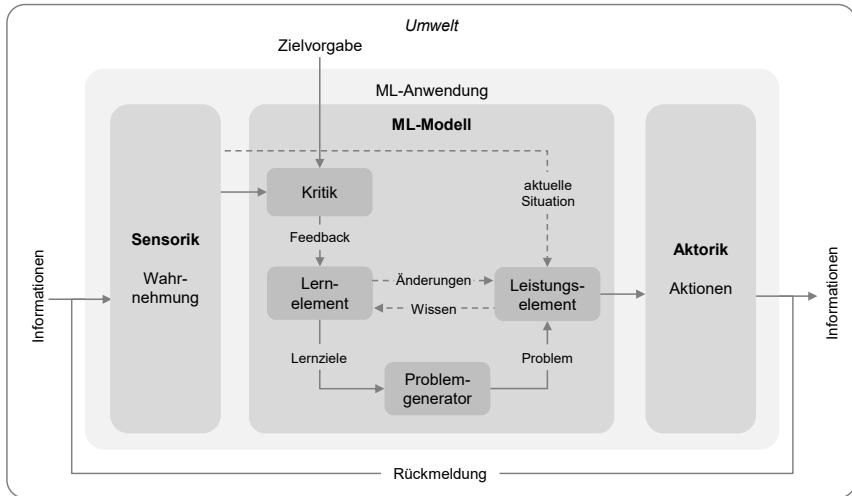


Abbildung 19: Funktionsprinzip von ML-Anwendungen³⁰³

ML-Anwendungen agieren ebenfalls mit der Umwelt, wobei zur Wahrnehmung von Informationen Sensoren und zur Ausgabe von Aktionen in Form der identifizierten Problemlösungen Aktuatoren eingesetzt werden.³⁰⁴ Im Falle von ML-Anwendungen, die im Sinne ihres äußeren Erscheinungsbildes primär Maschinen oder Roboter darstellen, handelt es sich bei den **Sensoren** u. a. um Kamerasysteme, Mikrofone oder Bewegungssensoren, die vorwiegend Veränderungen in der realen Umgebung erfassen sollen. Die **Aktuatoren** dienen hier vordergründig einer Umsetzung von elektrischen Signalen in mechanische Bewegungen, z. B. in Form von Endeffektoren bei Robotern. Im Falle von Anwendungen, die primär reinen Softwaresystemen entsprechen, werden diese beiden technischen Komponenten eher für „virtuelle“ Veränderungen eingesetzt. Die Sensorik dient demnach dem Bezug von Daten aus anderen Systemen oder aus der Eingabe durch den Menschen. Die Aktorik stellt demgegenüber eine datenseitige Übergabe der Ergebnisse an andere Systeme oder an eine Benutzerschnittstelle sicher. Die Informationsverarbeitung zwischen der Ein- und Ausgabe erfolgt innerhalb des sog. **ML-Modells**, welches sich modellhaft aus vier Komponenten zusammensetzt, die nachfolgend mit ihren Hauptaufgaben dargestellt sind:

- Leistungselement: Auswahl von Aktionen zur Lösung des Problems,
- Kritikelement: Bewertung von Aktionen,

wird dabei als eine spezielle Art von Software verstanden, welche sich in einer Umwelt befindet, diese wahrnimmt und auf sie einwirkt, um eigene Ziele zu verfolgen. Vgl. Franklin, Graesser (1997), S. 25 f.

³⁰³ Eigene Darstellung in Anlehnung an Russell, Norvig (2012), S. 83; Weinberger et al. (1994), S. 13

³⁰⁴ Hier und im weiteren Verlauf des Abschnittes handelt es sich um eine Synthese von Informationen aus Mitchell (1997), S. 11 f.; Russell, Norvig (2012), S. 83 f.; Weinberger et al. (1994), S. 14; Dillmann (1988), S. 19 ff.

- Lernelement: Verwaltung von Wissen und Entscheidung über Anpassung des Leistungselements im Sinne einer Verbesserung,
- Problemgenerator: Generierung von Problemen zur Maximierung des Wissens.

Das Leistungselement des Systems nimmt mittels der Sensoren ein Problem aus der Umwelt wahr. Auf Basis eines initialen Wissens, welches auf zuvor übergebenen Einzelfällen beruht, wählt es die geeignetste Aktion. Diese wird mittels der Aktuatoren an die Umwelt und als Wissen an das Lernelement übergeben. Die Aktion wird zur potenziellen Lösung des Problems ausgeführt und das damit verbundene Ergebnis im Sinne einer veränderten Umwelt mittels der Sensoren wieder erfasst. Das Ergebnis wird in Bezug auf eine externe Zielvorgabe durch das Kritikelement bewertet. Die Bewertung wird als Feedback an das Lernelement weitergegeben, welches dieses speichert und prüft, ob weiterhin ein Problem im Sinne der zu erreichenden Zielvorgabe vorliegt. Ist dies der Fall, initiiert das Lernelement eine Anpassung des Leistungselements, um bessere Ergebnisse bzw. Lösungen zu erzielen. Die angestrebte Anpassung wird in Form einer **(Lern-)Hypothese** formuliert, deren Ermittlung anhand von identifizierten Zusammenhängen in den übergebenen Einzelfällen und den bisherigen Ergebnissen stattfindet. Die angestrebte Anpassung des Leistungselements in Bezug auf die aktuelle Hypothese wird unter Verwendung der vorgegebenen Lernstrategie – welche vom jeweiligen Lernverfahren abhängen – durch den Problemgenerator spezifiziert. Dazu initiiert dieser passende Probleme für das Leistungselement, die zu neuem Wissen führen können. Ziel der Problemgenerierung ist eine möglichst umfassende **Erschließung des Entscheidungsfelds** im Sinne eines experimentellen Vorgehens. Das Leistungselement führt wiederum die potenziell geeignetste Aktion zur Lösung des aktuellen Problems aus, was zu einer iterativen Durchführung des Prozesses und zu einer kontinuierlichen Anpassung der Hypothesen führt. Der Prozess endet erst, wenn das Lernelement auf Grundlage der Kritik keine weitere Anpassung als notwendig erachtet, d. h. die Zielvorgabe erreicht ist.

Findet durch eine technisch lückenlose Integration der Informationsflüsse zwischen Aktorik und Sensorik die beschriebene Anpassung der Systeme in Form des Lernens ausschließlich auf Grundlage von Rückmeldungen aus der Umwelt zu zuvor ausgeführten Aktionen und weiteren Informationen ohne jegliche Einwirkung des Menschen statt, gilt der in Kapitel 2.4.1.1 eingeführte **Perception-Action-Cycle als geschlossen**. Dies stellt die technische Voraussetzung für eine vollständig autonome Ausführung von Prozessen dar.³⁰⁵

2.4.2.4 Vergleich beider KI-Paradigmen und Ableitung eines Lernbegriffes

Auf Grundlage der bisherigen Betrachtungen können wesentliche Stärken und Schwächen der symbolischen und subsymbolischen KI bzw. der darauf resultierenden Systeme abgeleitet werden. Diese sind in Tabelle 5 zusammengefasst und werden nachfolgend erläutert. Sie münden in einer Definition des systemseitigen Lernens für die vorliegende Arbeit.

³⁰⁵ Vgl. Zhu (2019), S. 1

	Subsymbolische KI (ML-Anwendungen)	Symbolische KI (Expertensysteme)
Stärken	<ul style="list-style-type: none"> - Fähigkeit zum induktiven Schließen; Erkennung neuer Zusammenhänge - Automatischer Wissenserwerb; Verringerung des Modellierungsaufwands - Hohe Anpassungsfähigkeit an neue Umwelteigenschaften und Probleme - Potenzial zur Schließung des Perception-Action-Cycle (autonome Ausführung) - Robustheit gegenüber teils fehlerhaften und unvollständigen Informationen 	<ul style="list-style-type: none"> - Fähigkeit zum deduktiven Schließen - Explizite Darstellung des Wissens, daher unmittelbare Interpretierbarkeit und einfache Erweiterbarkeit - Geringe Komplexität der Modellstruktur
Schwächen	<ul style="list-style-type: none"> - Abgängigkeit der Fähigkeiten zur Problemlösung von Datensituation - Tendenziell hoher Datenbedarf in Form von Trainingsfällen und ggf. Zusatzinformationen - Eingeschränkte Interpretierbarkeit, v. a. bei subsymbolischer Wissensrepräsentation (Black-Box-Modelle) - Hoher Rechenaufwand zur Ausführung 	<ul style="list-style-type: none"> - Keine Generierung von neuem Wissen (wahrheitserhaltend) - Geringe Anpassungsfähigkeit bei neuen Umwelteigenschaften und Problemen; Anpassung erfordert Umprogrammierung - Hoher Aufwand zur Erfassung und Modellierung des Wissens; oft nur durch Heuristiken erfassbar (Informationsverlust) - Geringe Genauigkeit bei komplexen, insbesondere dynamischen Problemen - Anfällig für fehlerhafte Informationen
Geeignete Probleme	Stochastische Entscheidungssituationen	Deterministische Entscheidungssituationen

Tabelle 5: Stärken und Schwächen der symbolischen und subsymbolischen KI

In den 1970er Jahren wurde mit der **Physical Symbol System Hypothesis (PSSH)** eine zentrale Hypothese der KI-Forschung formuliert, die davon ausging, dass ein symbolisches System bereits über die notwendigen und hinreichenden Mittel zur Realisierung eines allgemeinen intelligenten Handelns verfügt.³⁰⁶ Im selben Jahrzehnt wurden die ersten Expertensysteme erfolgreich zur Lösung von Problemen in der Praxis eingesetzt. Seitdem finden sie in vielen Bereichen Anwendung, u. a. zur Entscheidungsunterstützung in der Medizindiagnostik, zur Konfiguration von Kundenaufträgen und zur Automatisierung von Prozessen, u. a. zur Maschinensteuerung und in der Robotik.³⁰⁷ Anhand der Erkenntnisse aus diesem praktischen Einsatz lässt sich feststellen, dass die Systeme entsprechend ihrer technischen Gestaltung über die Fähigkeit zu deduktiven Schlüssen verfügen und ihr Wissen gut für Menschen interpretier- und erweiterbar ist (sog. **White-Box-Modelle**). Allerdings ist auch zu beobachten, dass das benötigte Wissen oft nur mit einem großen, in der Praxis nicht vertretbaren Aufwand identifiziert und modelliert werden kann, da dieses bei den Menschen mitunter nur unbewusst vorliegt, nur schwer beschreibbar ist oder falsch wahrgenommen wird (sog. Bias).³⁰⁸ Daher ist das in den jeweiligen Systemen gespeicherte **Wissen häufig unvollständig und fehlerhaft**. Dies gilt insbesondere in Fällen von sich ändernden Umfeldbedingungen bzw. Problemstellungen, deren systemseitige Berücksichtigung stets eine neue Programmierung durch den Menschen

³⁰⁶ Vgl. Newell, Simon (1976), S. 116

³⁰⁷ Vgl. Russell, Norvig (2012), S. 47 f.

³⁰⁸ Vgl. Weinberger et al. (1994), S. 10

erfordert. Entsprechend dieser **fehlenden Anpassungsfähigkeit** und der eingeschränkten Möglichkeit zur Erfassung des gesamten benötigten Wissens ist der Ansatz der symbolischen KI nur bedingt für die Lösung komplexer Probleme geeignet.³⁰⁹ Entgegen der ursprünglichen Annahme der PSSH begrenzt sich der Einsatz vielmehr auf bestimmte Anwendungsbereiche in der Praxis, welche sich tendenziell durch **deterministische Entscheidungssituationen** auszeichnen.³¹⁰

Im Gegensatz zu Expertensystemen ermöglicht der subsymbolische Ansatz einen vom Menschen unabhängigen Wissenserwerb, indem die entsprechenden ML-Anwendungen anhand von Daten zu Einzelfällen empirische Zusammenhänge erkennen und in Form einer induktiven Inferenz generalisierte Hypothesen zur Problemlösung für neue, unbekannte Fälle ableiten (siehe Abbildung 20). Dies ermöglicht die **Identifikation von neuen Lösungswegen**, die für den Menschen nicht oder nur mit einem hohen Aufwand ermittelbar sind. Ferner entfällt dadurch die Notwendigkeit der manuellen Programmierung des Wissens, was insbesondere bei einem großen Entscheidungsfeld den **Modellierungsaufwand erheblich reduzieren kann**. Mit dem automatischen Wissenserwerb geht auch ein adaptives Verhalten der Systeme einher, welches mittels Rückmeldungen aus der Umwelt initiiert wird. Anders als Vertreter der symbolischen KI sind ML-Anwendungen daher in der Lage, ihr Wissen an veränderte Umfeldbedingungen anzupassen, sodass auch eine Anwendung in stochastischen Entscheidungssituationen und damit eine **Lösung komplexer Probleme** ermöglicht werden. Entsprechend des resultierenden Potenzials zur Schließung des Perception-Action-Cycle stellen die Systeme zudem eine bedeutende Möglichkeit für die Autonomisierung von Prozessen dar. Als potenzielle Schwäche für bestimmte Anwendungsbereiche kann dagegen die subsymbolische Modellierung des Wissens angesehen werden, die mitunter zu sehr komplexen Strukturen führt, welche für den Menschen nur schwer interpretierbar sind (sog. **Black-Box-Modelle**³¹¹). Auch wenn der Ansatz des verteilten induktiven Lernens in vielen Fällen eine hohe Robustheit gegenüber falschen oder fehlenden Informationen sicherstellt, besteht eine inhärente Abhängigkeit der Systeme von den bereitgestellten Daten bzw. den darin enthaltenen Informationen. Ferner sind im Vergleich zu Expertensystemen tendenziell **höhere Anforderungen an die Rechenleistung** zur Ausführung der Systeme festzustellen.

³⁰⁹ Vgl. Jordan, Mitchell (2015), S. 255

³¹⁰ Diese Erkenntnis hat in der Historie von KI zu einer größeren Welle von Enttäuschungen geführt, die ab Mitte der 1980er mit einem erheblichen Rückgang von Fördermitteln verbunden war (sog. KI-Winter). Vgl. Russell, Norvig (2012), S. 48; Franklin (2014), S. 21

³¹¹ Vgl. Hastie et al. (2009), S. 352; Kuhn, Johnson (2013), S. 4; Marsland (2015), S. 249

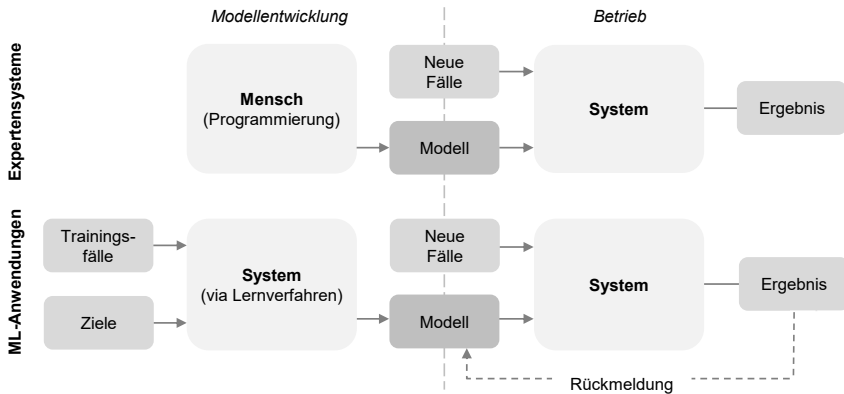


Abbildung 20: Schematischer Vergleich von Expertensystemen und ML-Anwendungen³¹²

Trotz der langen Forschungshistorie galt der praktische Einsatz von ML bzw. der subsymbolischen KI noch bis in die 1990er Jahre als nicht oder nur im beschränkten Maße realisierbar.³¹³ Wie einleitend in Kapitel 1.1 dargestellt, haben sich jedoch seitdem die hierfür benötigten Voraussetzungen, insbesondere durch den Anstieg der verfügbaren Daten und Rechenleistung, erheblich verbessert, sodass entsprechende Systeme mittlerweile in vielen Bereichen erfolgreich eingesetzt werden. Im Zuge dieser praktischen Realisierbarkeit hat sich aber auch das **Verständnis des systemseitigen Lernens verändert**. Wie die Ausführungen zu Beginn des Abschnittes zeigen, bestand hierfür historisch ein breites Spektrum an Ansätzen. Hierzu zählt das **Lernen durch Instruktion** in Form von durch den Menschen vorgegebenen Regeln, wie es bei Expertensystemen Anwendung findet, aber auch das sog. **mechanische Lernen**, bei dem für jedes betrachtete Problem vorab eine eindeutige Lösung in den jeweiligen Systemen durch den Menschen implementiert wird, sodass keinerlei systemseitige Verarbeitung zur Bewertung, Auswahl oder Neugestaltung des Lösungsraums stattfindet.³¹⁴ Dieser Ansatz ist mit dem menschlichen Auswendiglernen gleichzusetzen und findet Eingang bei der Entwicklung von konventioneller Software für die Ausführung definitionsgemäßer „Aufgaben“ (siehe Kapitel 2.3.1).³¹⁵ Bei diesen Realisierungsformen leistet jedoch der Mensch den entscheidenden Beitrag zur Veränderung des Wissens, sodass im gegenwärtigen wissenschaftlichen und öffentlichen Diskurs das systemseitige Lernen zumeist **nur noch mit ML assoziiert** wird.

In der vorliegenden Arbeit wird dieser Auffassung gefolgt. Für die Spezifizierung des damit verbundenen Begriffsverständnisses werden zwei bestehende Definitionen herangezogen.

³¹² Eigene Darstellung

³¹³ Vgl. Weinberger et al. (1994), S. 11

³¹⁴ Vgl. Carbonell et al. (1983), S. 8

³¹⁵ Vgl. Dillmann (1988), S. 27

Zum einen handelt es sich um die Definition von *Simon (1983)*, welche den für die Arbeit verwendeten **Lernbegriff** adressiert. Dieser wird mit der Fähigkeit von Systemen zur eigenständigen kontinuierlichen Verbesserung für die Lösung von Problemen gleichgesetzt:

*„Learning denotes changes in the system that are adaptive in the sense that they enable the system to do the same task or tasks drawn from the same population more efficiently and more effectively the next time.“*³¹⁶

Für das zugrundeliegende Verständnis von **Lernenden Systemen** wird die anwendungsorientierte Definition von *Acatech (2021)* genutzt, welche die Lernfähigkeit ausdrücklich in Verbindung mit ML setzt und mehrere systemtechnische Realisierungsformen aufzeigt. Anhand der hierbei angesprochenen Softwaresysteme leitet sich der in der Arbeit verwendete Begriff der **ML-Anwendungen** ab:

„Lernende Systeme sind Maschinen, Roboter und Softwaresysteme, die abstrakt beschriebene Aufgaben auf Basis von Daten, die ihnen als Lerngrundlage dienen, selbstständig erledigen, ohne dass jeder Schritt spezifisch vom Menschen programmiert wird. Um ihre Aufgabe zu lösen, setzen sie von Lernalgorithmen trainierte Modelle ein. Mithilfe des Lernalgorithmus können viele Systeme im laufenden Betrieb weiterlernen: Sie verbessern die vorab trainierten Modelle und erweitern ihre Wissensbasis. Lernende Systeme basieren auf Methoden der Künstlichen Intelligenz (KI), genauer: des maschinellen Lernens.“

2.4.3 Systematisierung von Machine Learning

Entsprechend der dynamischen Forschungsaktivitäten existieren viele methodische und konzeptionelle Ansätze im Kontext von ML, welche zudem eine stetige Veränderung und Erweiterung erfahren. Ausgehend von der vorgenommenen definitorischen Abgrenzung sollen diese Informationen in dem vorliegenden Abschnitt herausgearbeitet und systematisiert werden, wozu eine Betrachtung anhand von drei Ebenen erfolgt.³¹⁷ Einleitend werden die **Lerntypen** von ML mit ihrem Funktionsprinzip beschrieben, welche Auskunft über die unterschiedlichen Gestaltungsmöglichkeiten von Lernprozessen geben. Anschließend werden mit den **Lernverfahren** die Methoden von ML eingeführt, welche die eigentliche Problemlösung realisieren. Hierzu erfolgt eine Analyse wichtiger Eigenschaften von Lernverfahren, wodurch Stärken und auch Schwächen von ML in der Gesamtheit sichtbar werden.³¹⁸ Durch den gezielten Einsatz der Verfahren werden unterschiedliche Problemarten adressiert, welche auch als **Lernaufgaben** bezeichnet und abschließend systematisiert werden.

³¹⁶ Simon (1983), S. 28

³¹⁷ Die Namensgebung dieser drei Systematisierungsebenen variiert in der Literatur. Demnach werden die Lerntypen auch als Lernarten und die Lernverfahren auch als ML-Verfahren oder Lernalgorithmen bezeichnet.

³¹⁸ Auf die Beschreibung einzelner Verfahren, einschließlich deren Funktionsweise, wird in Hinblick auf das Forschungsziel der vorliegenden Arbeit verzichtet.

Zwischen den Ausprägungen entlang der drei Ebenen lassen sich teilweise technische Zusammenhänge feststellen, die zu einer häufigen Kombination bei den bereits umgesetzten Anwendungen führen. Eine eindeutige Zuordnung ist jedoch in den wenigsten Fällen möglich, da auch stets Abweichungen hiervon zu beobachten sind. Die in diesem Abschnitt vorgenommenen Zuordnungen, einschließlich der zusammenfassenden Darstellung in Abbildung 21, sind daher grundsätzlich als Indikationen zu betrachten. Ferner sind die genannten Lernverfahren nur als Auswahl populärer Vertreter zu verstehen, bei denen es sich zudem um übergeordnete Verfahrensarten handelt, die in der Praxis eine Vielzahl von Derivaten aufweisen.

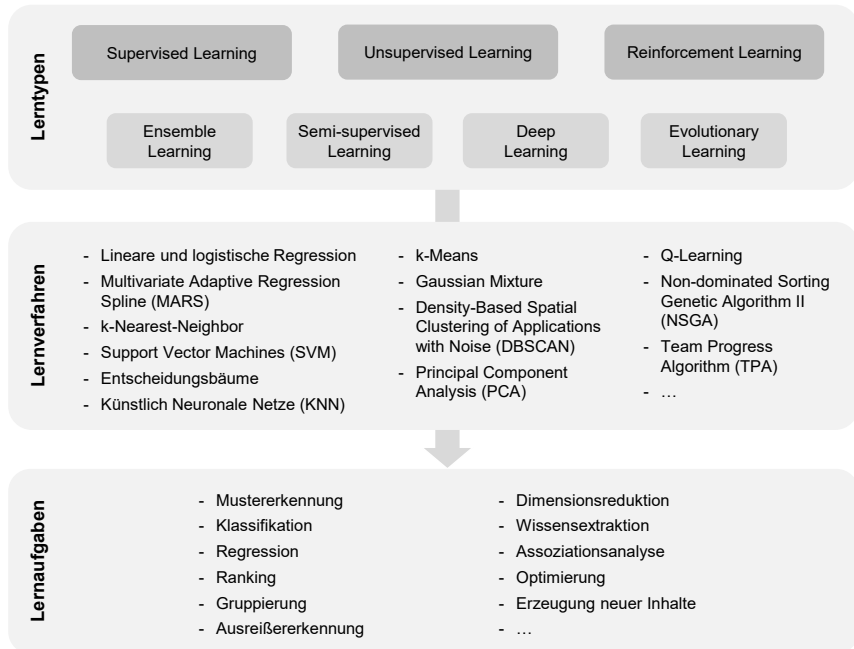


Abbildung 21: Systematisierung von ML³¹⁹

2.4.3.1 Lerntypen

Die Lerntypen stellen eine Möglichkeit zur grundlegenden Systematisierung von ML in Hinblick auf die **Gestaltung des Lernprozesses** dar. Mit dem Supervised Learning (SL), Unsupervised Learning (UL) und Reinforcement Learning (RL) bestehen drei Typen, die sich diesbezüglich eindeutig voneinander abgrenzen lassen.³²⁰ Während in der Literatur weitestgehend Konsens zu deren Zugehörigkeit zu ML besteht, weshalb im weiteren Verlauf auch von „Haupttypen“

³¹⁹ Eigene Darstellung. Es handelt sich um eine Auswahl von Verfahren, die bereits bei der Entwicklung von ML-Anwendungen im Logistikmanagement eingesetzt und im Rahmen der systematischen Literaturanalyse in der vorliegenden Arbeit identifiziert wurden (siehe Kapitel 3.1.1).

³²⁰ Vgl. Alpaydin (2010), S. 9; Russell, Norvig (2012), S. 811

gesprochen wird, variiert die Zuordnung und Abgrenzung von weiteren „Subtypen“. In der vorliegenden Arbeit werden mit dem Semi-supervised Learning (SSL) und dem Ensemble Learning (EL) zusätzlich zwei Typen betrachtet, die Mischformen der Haupttypen darstellen. Entsprechend der hohen Bedeutung wird auch das Deep Learning (EL) als ein separater Lerntyp berücksichtigt. Zudem wird mit dem Evolutionary Learning (EvL) ein weiterer Lerntyp einbezogen, der historisch einen separaten Technologiebereich darstellt, aber mittlerweile häufig auch als Bestandteil von ML angesehen wird.³²¹

Das **Supervised Learning** (überwachtes Lernen) stellt den bisher dominierenden Lerntyp dar. Mittels der eingesetzten Lernverfahren wird beim SL die Bestimmung einer Funktion angestrebt, welche die Zusammenhänge zwischen vorgegebenen Eingangsvariablen (sog. Features oder Merkmale) und Ausgabe- bzw. Zielvariablen³²² ermittelt, d. h. die Ausgabe durch die Eingabe erklärt (sog. Beobachtungen).³²³ Dazu werden bekannte Paare dieser beiden Variablen anhand historischer Daten übergeben, die auch als Trainingsfälle bzw. -beispiele bezeichnet werden. Die zu ermittelnde Funktion soll die beobachteten Zusammenhänge bestmöglich approximieren, um sie für die Lösung weiterer Fälle anwenden zu können.³²⁴ Das Ziel ist demnach, diejenige Funktion zu bestimmen, die sowohl den Zusammenhang der bekannten Paare möglichst genau abbildet, als auch im Sinne einer **Generalisierung** zu guten Ergebnissen bei neuen Fällen führt.³²⁵ Dieser Lerntyp wird als überwacht bezeichnet, da die Zielvariablen beim initialen Lernprozess bekannt sind (sog. markierte Daten bzw. Labels) und daher als ein externer „Lehrer“ fungieren.³²⁶ Bei den zu lösenden Problemen wird im Falle des SL nach der Art der Zielvariablen unterschieden. Im Falle von qualitativen, d. h. ordinalen oder kategorialen Variablen liegen häufig Klassifikationsprobleme vor. Bei quantitativen bzw. metrischen Variablen handelt es sich zumeist um Regressionsprobleme.³²⁷

Der maßgebliche Unterschied zwischen dem SL und dem **Unsupervised Learning** (unüberwachtes Lernen) ergibt sich aus den verfügbaren Informationen in den Trainingsfällen, die nur Eingangsvariablen umfassen; Zielvariablen oder andere Zusatzinformationen fehlen dagegen.³²⁸ Diese Abstinenz eines „Lehrers“ weist in vielen Fällen hohe Ähnlichkeiten zum menschlichen Lernen auf.³²⁹ Ziel beim USL ist es, mittels der eingesetzten Lernverfahren Regelmäßigkeiten in den Eingangsvariablen in Form von Mustern zu finden. Alle Daten werden anschließend entsprechend dieser Muster kategorisiert, wobei häufig eine Gruppierung von ähnlichen Eingangsvariablen zu Clustern angestrebt wird.³³⁰ Weiterhin wird im Kontext des USL

³²¹ Vgl. Marsland (2015), S. 6; Mitchell (1997), S. 269

³²² In diesem Zusammenhang wird auch von unabhängigen oder erklärenden Variablen (Prädiktoren) sowie von abhängigen Variablen gesprochen. Vgl. Hastie et al. (2009), S. 9

³²³ Vgl. Marsland (2015), S. 6; Alpaydin (2010), S. 11

³²⁴ Vgl. Murphy (2012), S. 3 ff.; Alpaydin (2010), S. 24

³²⁵ Vgl. Russell, Norvig (2012), S. 812 f.

³²⁶ Vgl. Hastie et al. (2009), S. 2

³²⁷ Vgl. Murphy (2012), S. 2; James et al. (2013), S. 28

³²⁸ Vgl. Murphy (2012), S. 9

³²⁹ Vgl. LeCun et al. (2015), S. 442

³³⁰ Vgl. Marsland (2015), S. 6

eine Kompression von Daten durch eine Dimensionsreduzierung sowie eine Erkennung von Ausreißern umgesetzt.³³¹

Das **Reinforcement Learning** (bestärkendes Lernen) kann in Bezug auf die verfügbaren Informationen zwischen dem SL und dem USL eingeordnet werden. Demnach werden den Lernverfahren Informationen zur Güte der erzielten Ergebnisse bereitgestellt, was den Zielvariablen im SL entspricht; Möglichkeiten zu deren Verbesserung werden jedoch nicht übergeben.³³² Beim RL ist es das Ziel, dass der jeweilige Algorithmus durch Ausprobieren verschiedener Möglichkeiten und deren Bewertung in Form einer externen Bestärkung einen bestmöglichen Lösungsweg findet. Dieser Lerntyp wird daher auch als „Lernen mit einem Kritiker“ bezeichnet.³³³ Entsprechend der Suche nach bestmöglichen Ergebnissen, die auch von bestehenden Lösungen abweichen können, wird RL oft für Optimierungsprobleme eingesetzt.³³⁴ Zusätzlich eignet sich dieser Lerntyp für Anwendungsfälle, in denen keine umfassenden Trainingsdaten zur Verfügung stehen.

Da der Algorithmus verschiedene Funktionen übernimmt, wird das Funktionsprinzip von RL häufig als Interaktion zwischen einem Agenten und seiner Umwelt beschrieben. Die Umwelt stellt das zu lösende Problem für den Agenten dar und liefert ihm gleichzeitig Informationen zu seinen Ergebnissen in Form einer Rückmeldung (Feedback).³³⁵ Hierzu wird das jeweilige Ergebnis anhand einer Funktion berechnet und entsprechend der Güte eine Belohnung oder Bestrafung induziert. Zu Beginn des Lernprozesses werden dem Agenten ein aktueller Zustand (State) und mögliche Handlungsspielräume (Aktionen) übergeben. Sein Ziel besteht in der Ermittlung derjenigen Aktion, die ausgehend von diesem Zustand seine Belohnung maximiert. Die Aktion entspricht einer Sequenz mehrerer Schritte, die das jeweilige Problem lösen sollen. Die Güte einer Aktion wird immer als Teil dieser Sequenz in Hinblick auf ihren Beitrag zur Problemlösung bewertet. Die Sequenz der besten Aktionen zur Zielerreichung wird als Strategie (Policy) bezeichnet und kann für neue Probleme verwendet werden.

Das **Semi-supervised Learning** (halbüberwachtes Lernen) stellt eine Verbindung des SL und USL dar.³³⁶ Es findet demnach bei Problemen Anwendung, zu denen mehr Informationen als typischerweise für das USL vorhanden sind; diese Informationen aber nicht für eine reine Nutzung des SL ausreichen. Das Ziel beim SSL ist es, aus den wenigen verfügbaren Zusatzinformationen auf eine große Anzahl weiterer Daten zu schließen, weshalb gleichzeitig Ansätze des SL und des USL eingesetzt werden.³³⁷ Ein typisches Problem im Kontext des SSL stellt die sog. halbüberwachte Klassifikation dar, bei der auf Basis der Trainingsfälle nur wenige Paare von Eingangs- und Zielvariablen bestehen.³³⁸ Eine weitere Problemstellung ist das sog.

³³¹ Vgl. Zhu, Goldberg (2009), S. 2

³³² Vgl. hierzu und zum folgenden Satz Marsland (2015), S. 231

³³³ Vgl. Alpaydin (2010), S. 448

³³⁴ Vgl. Mitchell (1997), S. 367

³³⁵ Vgl. hierzu und zu diesem Abschnitt Vgl. Marsland (2015), S. 231 f.

³³⁶ Vgl. Chapelle et al. (2006), S. 2

³³⁷ Vgl. Russell, Norvig (2012), S. 811; Marsland (2015), S. 20

³³⁸ Vgl. hierzu und zu diesem Abschnitt Zhu, Goldberg (2009), S. 9

eingeschränkte Clustering, bei dem analog zum USL keine Labels in den Daten vorliegen. Allerdings existieren weitere Informationen, die bspw. angeben, dass einzelne Werte zu bestimmten Clustern gehören oder dass die Cluster eine bestimmte Größe haben müssen. Anstatt einer unüberwachten Gruppierung werden diese Informationen im Sinne eines externen „Lehrers“ berücksichtigt. Da oftmals bei praktischen Anwendungsfällen grundsätzlich viele Daten verfügbar sind, wovon jedoch nur wenige über eine Markierung verfügen, weist das SSL einen hohen praktischen Wert auf.³³⁹

Der Lerntyp des **Ensemble Learning** (Gruppenlernen) sieht eine Kombination mehrerer Lernverfahren zur gezielten Nutzung von deren Stärken vor.³⁴⁰ Hierfür bestehen mehrere Ansätze, die sich durch die Popularität des Lerntyps stetig erweitern.³⁴¹ Die Ansätze lassen sich dahingehend unterscheiden, ob beim Lernprozess unterschiedliche oder mehrmals dieselben Verfahren Anwendung finden. Im Falle von unterschiedlichen Verfahren stellt Stacking (Kurzform für Stacked Generalization) einen bekannten Ansatz dar.³⁴² Mehrmals dieselben Verfahren werden u. a. beim Boosting und Bagging (Kurzform für Bootstrap Aggregating) eingesetzt.³⁴³ Beim **Boosting** werden die verfügbaren Trainingsfälle in verschiedene Teile aufgeteilt, anhand derer Algorithmen des gleichen Lernverfahrens lernen. In mehreren Durchläufen findet eine Gewichtung der einzelnen Algorithmen (sog. Lerner) hinsichtlich ihrer Ergebnisse statt. Die schlechter bewerteten Ergebnisse, d. h. die schwachen Lerner, werden anschließend stärker gewichtet, um diese im weiteren Lernprozess in Hinblick auf deren Verbesserung zu fokussieren. Beim **Bagging** werden aus den Trainingsfällen zufällig Stichproben gezogen, anhand derer ein Algorithmus lernt. Die genutzten Datensätze werden anschließend wieder „zurückgelegt“ und der Vorgang beginnt von Neuem. Die Ergebnisse der einzelnen Durchläufe werden anschließend zur Ermittlung des Gesamtergebnisses gewichtet. Mit **Random Forest** existiert ein weiterer Ansatz, der das Prinzip des Bagging nutzt. Hierbei werden mehrere Entscheidungsbäume als Lernverfahren eingesetzt, die auf Basis zufälliger Stichproben lernen. Das Ergebnis, welches von den meisten Bäumen gewählt wurde, entspricht dem Gesamtergebnis.

Das **Deep Learning** (tiefes Lernen) stellt hinsichtlich des Lernprozesses keinen abweichenden Ansatz dar. Vielmehr handelt es sich um die spezifische Gestaltung eines bestimmten Lernverfahrens in Form von künstlich neuronalen Netzen (KNN). Deren Funktionsprinzip orientiert sich am menschlichen Gehirn, indem modellhaft mehrere Neuronen vorgesehen sind.³⁴⁴ Ein klassisches KNN weist eine zweischichtige Architektur von Neuronen auf, bei der Neuronen in einer Eingangsschicht (Input Layer) Werte aus der Umwelt erhalten und Neuronen in einer Ausgabeschicht (Output Layer) die Ergebnisse ausgeben. Ferner existieren auch

³³⁹ Vgl. Chapelle et al. (2006), S. 11

³⁴⁰ Vgl. Hastie et al. (2009), S. 605. Es werden mitunter auch mehrere Lernverfahren sequenziell zur Realisierung verschiedener Lernaufgaben eingesetzt, indem bspw. zuerst eine Strukturierung des Datensatzes per Klassifikation erfolgt, deren Ergebnisse anschließend für Regressionen genutzt werden. Diese Fälle sind jedoch nicht dem EL zuzuordnen, da es sich um getrennte Lösungsschritte handelt.

³⁴¹ Vgl. Russell, Norvig (2012), S. 880; Murphy (2012), S. 581

³⁴² Vgl. Hastie et al. (2009), S. 605

³⁴³ Vgl. hierzu und zu diesem Abschnitt James et al. (2013), S. 316 ff.

³⁴⁴ Vgl. hierzu und zu diesem Abschnitt Alpaydin (2010), S. 233 ff.

KNN, bei denen sich zwischen der Ein- und Ausgabeschicht weitere Neuronen auf sog. verdeckten Schichten (Hidden Layer) befinden (siehe Abbildung 22). Diese werden durch vorausgehende Neuronen mittels gewichteter Verbindungen aktiviert, sodass es zu einer gegenseitigen Beeinflussung der Neuronen in den Netzen kommt. Das Ziel des Lernprozesses ist es, diejenigen Gewichte entlang der Netze zu identifizieren, die die jeweiligen Probleme bestmöglich lösen. Es handelt sich bei den Lösungen daher um Sequenzen einer unterschiedlich starken Aktivierung der einzelnen Neuronen. In den Fällen einer aus mehreren verdeckten Schichten bestehenden KNN-Architektur wird auch von **tiefen neuronalen Netzen** (Deep Neuronal Network), gesprochen.³⁴⁵ Die darauf basierende Begründung eines separaten Lerntyps im Kontext von ML geht auf *LeCun et al. (2015)* zurück.




Abbildung 22: Aufbau eines tiefen neuronalen Netzes (Deep Learning)³⁴⁶

Der Lerntyp des **Evolutionary Learning** (Evolutionäres Lernen) orientiert sich an natürlichen biologischen Entwicklungen, indem zum Erreichen von Zielen eine Veränderung von Populationen stattfindet.³⁴⁷ Die Populationen stellen in diesem Kontext die Gesamtheit an möglichen Lösungen für Probleme dar (Hypothesen). Zu Beginn des Lernprozesses wird den eingesetzten Lernverfahren, bei denen es sich um sog. evolutionäre oder genetische Algorithmen (GA) handelt, ein möglicher Lösungsraum an Hypothesen übergeben. Das Ziel der Algorithmen ist es, aus diesen Möglichkeiten die beste Hypothese zu ermitteln. Die Ergebnisse werden anhand eines vordefinierten Maßes in Form einer sog. Fitnessfunktion bewertet, welche das zu erreichende Optimum abbildet. Die Algorithmen versuchen die Probleme durch eine iterative Anpassung (Mutation) von Teilen der aktuell besten Hypothese zu lösen. Diese wird bei den einzelnen Schritten verändert, indem die Nachfahren der aktuell besten Hypothesen entweder in die nächste Generation übertragen oder zur Erzeugung neuer „Nachkommen“ mittels genetischer Operationen verändert werden. Durch die iterative Ermittlung der Ergebnisse zeigt das EvL eine hohe Eignung für komplexe Optimierungsprobleme. Es wird aber auch u. a. bei Regressionsproblemen eingesetzt.

³⁴⁵ Eine eindeutige Anzahl der benötigten Schichten für diese Namensgebung existiert nicht. Vgl. Schmidhuber (2015), S. 86

³⁴⁶ Eigene Darstellung

³⁴⁷ Vgl. hierzu und zu diesem Abschnitt Mitchell (1997), S. 49 ff.

2.4.3.2 Lernverfahren

Die eigentliche Lösung von Problemen im Kontext von ML, d. h. die Realisierung der jeweiligen Lernaufgabe, erfolgt durch den Einsatz der Lernverfahren, bei denen es sich um einfache bis teils sehr komplexe mathematisch-statistische Verfahren handelt, die durch Überführung in Algorithmen durch IT-Systeme ausführbar sind. Für die Umsetzung heutiger ML-Anwendungen besteht bereits eine Vielzahl vorgefertigter Algorithmen, die in Bibliotheken der Entwicklungsumgebungen zu den relevanten Programmiersprachen, wie R, Python und Matlab, aufrufbar sind und für den jeweiligen Anwendungsfall im Rahmen ihrer Einbettung in das ML-Modell angepasst werden müssen. Dies erfolgt durch eine Konfiguration von verfahrensspezifischen Parametern, die in zwei Gruppen zu unterscheiden sind. Zum einen existieren Parameter, die automatisch anhand der Daten durch die Verfahren bzw. Modelle ermittelt werden und von außen nicht beeinflussbar sind. Als Beispiele sind die Gewichte vom KNN und die Koeffizienten von linearen Regressionen zu nennen. Zum anderen existieren bei vielen Lernverfahren sog. **Hyperparameter**, deren Ausprägungen durch den Menschen vorgegeben werden müssen.³⁴⁸ Dazu gehören z. B. die Tiefe und Anzahl der Bäume bei entscheidungsbaum-basierten Verfahren, die Anzahl der Hidden Layers bei KNN oder die Anzahl der Cluster beim k-Means-Verfahren. Den Hyperparametern wird eine hohe Bedeutung zuteil, da sie den Lernprozess der Algorithmen und damit die Ergebnisqualität der Modelle erheblich beeinflussen.³⁴⁹

Nachfolgend werden im Sinne der angestrebten Systematisierung mehrere Eigenschaften von Lernverfahren analysiert, die deren Eignung für unterschiedliche Anwendungsfälle determinieren und bei der Bestimmung von geeigneten Verfahren in den jeweiligen Entwicklungsprozessen zu berücksichtigen sind. Aus dieser Entwicklungsperspektive sind die Fähigkeiten als mögliche Kriterien vorab in Tabelle 6 zusammengefasst.

Kriterium	Beschreibung bzw. Ausprägungen
Genauigkeit	Erzielbare Güte bei neuen Fällen
Interpretierbarkeit	Nachvollziehbarkeit des Lösungsweges für Menschen
Lernaufgabe	Klassifikation, Regression, Optimierung u. a.
Umfang der Daten	Anzahl der Fälle und Variablen
Art der Zusammenhänge	Linear, nichtlinear
Art der Daten	Metrisch, kategorial u. a.
Qualität der Daten	Fehler, Vollständigkeit, Varianz, Skalierung (Normalisierung)
Modellierungsaufwand	Anzahl von zu konfigurierenden Hyperparametern
Recheneffizienz	Benötigte Rechenleistung für Ausführung

Tabelle 6: Kriterien zur Auswahl von Lernverfahren

³⁴⁸ Vgl. Richter (2019), S. 14

³⁴⁹ Vgl. Sammut, Webb (2017), S. 822

Die **Genauigkeit** (sog. Performance) ist eine zentrale Eigenschaft der Verfahren bzw. der darauf basierenden ML-Modelle und beschreibt die Abweichung zwischen den erzielten Ergebnissen und den realen Ausprägungen. Diese Eigenschaft kann durch unterschiedliche statistische Metriken, aber auch durch prozessspezifische Güteindizes bewertet werden. Für Klassifikationsprobleme werden häufig die Accuracy und die Wahrheitsmatrix (Confusion Matrix)³⁵⁰ sowie der F-Score³⁵¹ eingesetzt. Für Regressionsprobleme eignen sich u. a. die Maße des Mean Squared Error (MSE) und des Root Mean Square Error (RMSE) sowie des Mean Absolute Error (MAE). Grundsätzlich ist die Genauigkeit von der jeweiligen Problemstellung abhängig, sodass keine allgemeingültigen Aussagen zu einzelnen Lernverfahren getroffen werden können. Bei einer Betrachtung von bestimmten Problemarten anhand der Komplexitätsmerkmale aus Kapitel 2.3.3 lassen sich allerdings deutliche Leistungsunterschiede feststellen. Demnach existieren Verfahren, die bspw. bei einer hohen Variablenzahl (Dimensionalität) und/oder bei nichtlineareren Zusammenhängen zwischen den Variablen eine vergleichsweise hohe Ergebnisqualität erzielen, wozu u. a. Ensemble-Verfahren, SVM und NN zählen.³⁵²

Bei der Bewertung der Genauigkeit sind neben den Ergebnissen auf Grundlage der bereitgestellten Trainingsfälle die Ergebnisse für neue Fälle, die dem jeweiligen Modell unbekannt sind, ausschlaggebend. Hieraus lassen sich wichtige Aussagen zur Fähigkeit der **Generalisierbarkeit** ableiten.³⁵³ Hierzu lässt sich feststellen, dass bestimmte Lernverfahren zu einer Überanpassung (Overfitting) an die Trainingsfälle neigen, was in Bezug auf diese Fälle zu einer hohen Genauigkeit führt, aber die Ergebnisqualität bei neuen Fällen einschränkt – auch wenn diese nur leicht von den bekannten Beobachtungen abweichen. Diese Eigenschaft wird als **Varianz** beschrieben und kann trotz der fehlenden Generalisierung, insbesondere bei sehr ähnlichen Problemstellungen, zweckmäßig sein.³⁵⁴ Als Beispiel für eine tendenziell hohe Varianz sind Entscheidungsbäume zu nennen, wohingegen lineare Regressionen allgemein eine geringe Varianz aufweisen.³⁵⁵ Auf der anderen Seite existieren Verfahren, die zu einer Unteranpassung (Underfitting) tendieren, indem sie eine Generalisierung ihrer Ergebnisse anstreben.³⁵⁶ Diese Eigenschaft wird als **Bias** beschrieben und kann neben positiven Effekten ebenfalls zu einer eingeschränkten Genauigkeit führen, indem wichtige Zusammenhänge in den Trainingsfällen nicht adäquat berücksichtigt werden.³⁵⁷ Die Realisierung beider Eigenschaften ist daher mit einem Zielkonflikt verbunden, der als Bias-Variance-Tradeoff bezeichnet wird.³⁵⁸

Ein weiterer Zielkonflikt lässt sich für die **Interpretierbarkeit** der Verfahren feststellen, welche die Verständlichkeit des jeweiligen Lösungsweges für den Menschen ausdrückt. Die Ausprägungen dieser Fähigkeit verhalten sich häufig diametral zur Genauigkeit im Sinne der zuvor

³⁵⁰ Vgl. Marsland (2015), S. 21 ff.

³⁵¹ Vgl. Murphy (2012), S. 183

³⁵² Vgl. James et al. (2013), S. 25 f.; Hastie et al. (2009), S. 351

³⁵³ Vgl. hierzu und zum folgenden Satz Alpaydin (2010), S. 39

³⁵⁴ Vgl. James et al. (2013), S. 25 f.

³⁵⁵ Vgl. James et al. (2013), S. 316

³⁵⁶ Vgl. Alpaydin (2010), S. 39

³⁵⁷ Vgl. Richter (2019), S. 12

³⁵⁸ Vgl. Marsland (2015), S. 35

beschriebenen Generalisierung (Abbildung 23). Als Beispiel für eine hohe Interpretierbarkeit bei einer gleichzeitig geringen Genauigkeit bzw. Generalisierbarkeit sind klassische statistische Verfahren zu nennen, wie z. B. logistische und lineare Regressionen.³⁵⁹ Demgegenüber stehen Verfahren, die eine Generalisierung ermöglichen, aber wiederum sehr schwer zu interpretieren sind, weshalb in diesem Zusammenhang auch von **Black-Box-Modellen** gesprochen wird.³⁶⁰ Hierzu zählen insbesondere mehrstufige NN, aber auch genetische Algorithmen.³⁶¹ Eine geringe Interpretierbarkeit kann zu Einschränkungen bei der gezielten Verbesserung der Modelle in der Entwicklung führen, hat aber v. a. Auswirkungen auf den praktischen Einsatz, da in einigen Anwendungsfällen eine Transparenz über die Entscheidungsfindung notwendig ist. Als Beispiel für einen Kompromiss zwischen beiden Eigenschaften können entscheidungsbaumbasierte Verfahren angesehen werden, die neben einer im Vergleich zu anderen Verfahren tendenziell besseren Generalisierbarkeit u. a. auch eine automatische Ausgabe der Features hinsichtlich des jeweiligen Einflusses auf die erzielten Ergebnisse ermöglichen (sog. Feature Importance), wodurch der Lösungsweg nachvollziehbarer wird.




Abbildung 23: Zielkonflikt der Genauigkeit und Interpretierbarkeit von Lernverfahren³⁶²

Aus Nutzersicht nehmen die Genauigkeit und Interpretierbarkeit eine bedeutende Rolle bei der Charakterisierung der Lernverfahren ein. Darüber hinaus existiert noch eine Vielzahl weiterer Merkmale, die teilweise im Zusammenhang mit der Genauigkeit stehen. Neben der Realisierbarkeit bestimmter Lernaufgaben gehört dazu v. a. der Umgang mit bestimmten datenseitigen Voraussetzungen.³⁶³ Demnach existieren Verfahren, wie bspw. NN, welche eine vergleichsweise hohe Anzahl an Trainingsfällen für die Erzielung einer hohen Genauigkeit benötigen. Auch zeigen sich Unterschiede in Bezug auf den Umgang mit Einschränkungen bei der Datenqualität, die sich u. a. durch unvollständige Informationen (sog. Missing Values), enthaltene

³⁵⁹ Vgl. James et al. (2013), S. 26

³⁶⁰ Vgl. Hastie et al. (2009), S. 359

³⁶¹ Vgl. Marsland (2015), S. 73, 225

³⁶² Eigene Darstellung in Anlehnung an James et al. (2013), S. 25 mit Inhalten aus Hastie et al. (2009), S. 351.

³⁶³ Vgl. Hoppe (1996), S. 12

Ausreißer, aber auch durch inhaltliche Fehler ergeben können und allgemein als **Rauschen** (Noise) bezeichnet werden.³⁶⁴ Im Falle einer geringen Beeinflussung der Genauigkeit durch solche Einschränkungen wird von einer **Robustheit** der Verfahren gesprochen, was bspw. auf Entscheidungsbäume zutrifft.³⁶⁵ Als weitere Eigenschaften der Verfahren kann deren Ressourcen- bzw. **Recheneffizienz** bewertet werden. Diese bezieht sich u. a. auf die Anzahl der o. g. Hyperparameter und den damit verbundenen Aufwand für deren Konfiguration sowie auf die benötigte Rechenleistung für das Training der Verfahren bzw. Modelle und für deren Ausführung im Betrieb.

Anhand der beschriebenen Eigenschaften ist festzustellen, dass die einzelnen Lernverfahren sowohl Stärken als auch Schwächen aufweisen, die problemspezifisch zu bewerten sind. Dies führt dazu, dass kein allgemeingültiges bestes Verfahren existiert, sondern es sich stets um Kompromisslösungen unter Abwägung mehrerer Kriterien handelt, was auch als **No-free lunch-Theorem** („Nichts ist umsonst“) bezeichnet wird.³⁶⁶

2.4.3.3 Lernaufgaben

Anhand der bisher umgesetzten Anwendungen lassen sich mehrere Arten von Problemen ableiten, die mittels ML lösbar sind und die auf den Einsatz unterschiedlicher Lernverfahren im Kontext verschiedener Gestaltungsformen der Lernprozesse zurückgehen. Diese abstrahierten Probleme werden auch als Lernaufgaben bezeichnet und stellen die **technischen Fähigkeiten von ML** dar. Nachfolgend werden wesentliche Lernaufgaben³⁶⁷ mit potenziellen Anwendungsbeispielen aus dem Logistikmanagement dargestellt. Im Falle eines repräsentativen Zusammenhangs wird zusätzlich ein Bezug zu einzelnen Lerntypen hergestellt, wobei auf die Nennung von SSL, EL und DL aufgrund der weitestgehenden Analogie bei einer Anwendung von SL und USL verzichtet wird.

Eine übergreifende Lernaufgabe von ML, welche die Grundlage für einen Großteil der weiteren Aufgaben darstellt, ist die **Mustererkennung**. Anhand der übergebenen Daten zu Problemstellungen sind die Lernverfahren in der Lage, bestimmte Zusammenhänge bzw. Regelmäßigkeiten zu erkennen, z. B. in Form von Korrelationen, die dem Menschen möglicherweise bisher unbekannt sind.³⁶⁸ Neben der Erkennung von Sprache und Bildern, wie sie in den KI-Teilbereichen NLP und Computer Vision Anwendung findet, dient dies u. a. der Detektion von logistischen Objekten und Störungsursachen.

³⁶⁴ Vgl. Alpaydin (2010), S. 30 f., 89

³⁶⁵ Vgl. Hastie et al. (2009), S. 351

³⁶⁶ Vgl. Wolpert, Macready (1997), S. 70 f.

³⁶⁷ Ausgehend von verschiedenen Ansätzen in der Literatur orientiert sich die vorliegende Arbeit an der Systematisierung von Alpaydin (2010). Die Aufgaben sind nicht disjunkt, sondern bauen teilweise technisch aufeinander auf.

³⁶⁸ Vgl. Alpaydin (2010), S. 6

Bei einer **Klassifikation** teilt das jeweilige Lernverfahren die übergebenen Daten bzw. die darin enthaltenen Fälle in gegebene Klassen ein.³⁶⁹ Die ermittelten Funktionen zur Bestimmung der Klassenzugehörigkeit (Classifier) ermöglichen eine Zuordnung unbekannter Fälle.³⁷⁰ Als Beispiel ist die Segmentierung von Materialien in fehlerhafte und nichtfehlerhafte Teile zu nennen. Das Pendant für metrische Werte stellt die **Regression** dar, bei der zwischen einer oder mehrerer Eingangsvariablen und einer Zielvariable Zusammenhänge in Form von Regressionsfunktionen bestimmt werden, wobei es sich um lineare oder nichtlineare Beziehungen handeln kann.³⁷¹ Die Regression dient insbesondere der Ermittlung zukünftiger Zustände und Ereignisse, z. B. in Form von Nachfragemengen oder Prozesszeiten. Beide Aufgaben werden insbesondere im Kontext des SL realisiert.³⁷² Anstatt eines einzelnen Wertes können die Lernverfahren dabei auch die Rangfolge von mehreren Werten ermitteln. Bei dieser Aufgabe, die als **Ranking** bezeichnet wird, findet anhand der Daten eine Ermittlung der Ähnlichkeit zwischen den Werten in Bezug auf bestimmte Merkmale statt.³⁷³ Sie kann z. B. für die Bewertung von Lieferanten eingesetzt werden.

Bei der **Gruppierung** bzw. Clusteranalyse werden ähnliche Daten zu Gruppen bzw. Clustern zusammengefasst.³⁷⁴ Im Gegensatz zur Klassifikation werden diese Gruppen jedoch nicht vorgegeben, sondern eigenständig durch die Lernverfahren anhand von Zusammenhängen in den Eingangsvariablen ermittelt.³⁷⁵ Bei dem Gruppierungsvorgang wird eine möglichst große Ähnlichkeit von Objekten innerhalb eines Typs bei einer gleichzeitig hohen Unähnlichkeit zu den Objekten eines anderen Typs angestrebt.³⁷⁶ Die Gruppierung kann u. a. zur Systematisierung von Kunden unter Berücksichtigung mehrerer Merkmale genutzt werden. Ihre Realisierung erfolgt v. a. im Kontext des USL.³⁷⁷

Bei der **Ausreißerkennung** werden auffällige Werte in den Daten ermittelt, die vom Großteil der restlichen Werte abweichen.³⁷⁸ Dies erfolgt mittels der Bestimmung gemeinsamer Merkmale und der diesbezüglichen Bewertung einzelner Werte. Im Falle von Abweichungen werden diese Werte als Ausreißer deklariert, wobei es sich um Anomalien (Anomaly Detection) oder neuartige, bisher unbekannte Fälle (Novelty Detection) handeln kann.³⁷⁹ Ersteres dient u. a. der Identifizierung von ungewünschten Zuständen in Form von Störungen. Die Ausreißerkennung wird insbesondere im Kontext von SL und USL realisiert.

Bei der **Dimensionsreduktion** werden die bereitgestellten Daten komprimiert, ohne dass relevante Informationen für den Lernprozess verloren gehen. Dies erfolgt insbesondere durch

³⁶⁹ Vgl. James et al. (2013), S. 127

³⁷⁰ Vgl. Alpaydin (2010), S. 5

³⁷¹ Vgl. Russell, Norvig (2012), S. 812

³⁷² Vgl. Alpaydin (2010), S. 11

³⁷³ Vgl. Murphy (2012), S. 300 f.

³⁷⁴ Vgl. Alpaydin (2010), S. 11 f.

³⁷⁵ Vgl. Russell, Norvig (2012), S. 944 f.

³⁷⁶ Vgl. Kuckartz (2010), S. 555 f.

³⁷⁷ Vgl. Alpaydin (2010), S. 11

³⁷⁸ Vgl. Zhu, Goldberg (2009), S. 2

³⁷⁹ Vgl. Alpaydin (2010), S. 9

die Reduktion um irrelevante oder redundante Eingangsvariablen, wohingegen die Anzahl der Trainingsfälle erhalten bleibt.³⁸⁰ Hierzu ermitteln die Lernverfahren eine Funktion, welche die Zusammenhänge in den Daten erklärt, sodass u. a. redundante oder miteinander korrelierende Features entfernt werden können.³⁸¹ Durch die Weiternutzung der reduzierten Daten kann der Ressourcenbedarf für deren Analyse und Speicherung sowie für die Ausführung der darauf basierenden Anwendungen reduziert werden.³⁸² Die Dimensionsreduktion wird insbesondere im Kontext des USL umgesetzt.

Im Kontext der bisher beschriebenen Lernaufgaben erfolgt eine Ermittlung von Funktionen, welche erkannte Zusammenhänge in den bereitgestellten Daten abbilden, um diese systemseitig für neue Fälle anzuwenden. Die damit verbundenen Informationen zur Lösung der jeweiligen Problemstellungen können aber auch extrahiert und den Nutzern als neues Wissen bereitgestellt werden.³⁸³ Bei dieser **Wissensextraktion** kann es sich z. B. um Regeln oder die Bedeutung von Eingangsvariablen für den Lernprozess handeln. Ein spezieller Fall der Wissensextraktion stellt die **Assoziationsanalyse** dar, bei der die ermittelten Zusammenhänge zwischen gemeinsam auftretenden Phänomenen bereitgestellt werden.³⁸⁴ Bei der Lernaufgabe werden zum einen Assoziationen ermittelt, d. h. Merkmale, die das Auftreten anderer Merkmale implizieren, und zum anderen etwaige Sequenzen dargestellt, d. h. Reihenfolgen des zeitlichen Eintretens der Merkmale.³⁸⁵ Hierdurch können z. B. Abhängigkeiten zwischen auftretenden Störungen erkannt werden. Beide Aufgaben werden sowohl im Kontext von SL als auch von USL realisiert.

Anstelle des wahrscheinlichsten Wertes auf Basis bestehender Beobachtungen, können Lernverfahren gezielt zur Bestimmung bestmöglicher Werte in Hinblick auf definierte Zielstellungen eingesetzt werden. Im Kontext dieser **Optimierung** ermöglichen die Lernverfahren auch die Lösung komplexer Probleme mit vielen dynamischen Variablen und konfliktären Zielen.³⁸⁶ Dies kann im logistischen Kontext u. a. für die Ermittlung optimaler Maschinenbelegungen und Transportrouten eingesetzt werden. Diese Lernaufgabe ist mittels mehrerer Lerntypen realisierbar, wobei das RL und EvL entsprechend ihres Funktionsprinzips eine besondere Bedeutung einnehmen.

Die Ermittlung bisher unbekannter Lösungen im Rahmen der Optimierung stellt gleichzeitig eine **Erzeugung neuer Inhalte** dar. Diese Lernaufgabe wird zudem durch spezifische Lernverfahren adressiert, insbesondere in Form von Generative Adversarial Networks (GAN), welche die Erzeugung künstlicher Werte zu realen Phänomenen ermöglichen, wobei es sich nicht nur um graduelle Veränderungen handeln kann, sondern auch um eine Realisierung gänzlich

³⁸⁰ Vgl. Zhu, Goldberg (2009), S. 2

³⁸¹ Vgl. Marsland (2015), S. 129

³⁸² Vgl. Alpaydin (2010), S. 8 f.

³⁸³ Vgl. Alpaydin (2010), S. 8

³⁸⁴ Vgl. Alpaydin (2010), S. 4

³⁸⁵ Vgl. Hastie et al. (2009), S. 487 f.

³⁸⁶ Vgl. Mitchell (1997), S. 368

neuer Gestaltungsformen.³⁸⁷ In diesem Zusammenhang kann daher im weiteren Sinne von einer **Kreativität** gesprochen werden. Neben der Generierung von Sprache dient diese Lernaufgabe u. a. der Gestaltung von Produkten.

2.5 Synthese: ML-Anwendungen im Logistikmanagement

Das Kapitel 2 diente der Erfassung relevanter Theorien für das angestrebte Forschungsziel sowie der Beschreibung und Abgrenzung des Untersuchungsfeldes in Bezug auf dessen prozessuale und technische Dimension. In diesem Unterkapitel werden die erzielten Erkenntnisse unter Berücksichtigung der Definitionen aus Kapitel 2.1.1 zusammengeführt und bedeutende Referenzstrukturen für die weitere Untersuchung abgeleitet.

ML stellt einen vielfältigen Verbund aus mathematisch-statistischen Verfahren dar. Dieser wird für die Untersuchungen in der vorliegenden Arbeit auf jene Lernverfahren und damit verbundenen Lernaufgaben beschränkt, welche den drei übergreifenden Lerntypen des Supervised, Unsupervised und Reinforcement Learning sowie den vier Subtypen des Semi-supervised, Ensemble, Deep und Evolutionary Learning zuzuordnen sind. Als datengestützte Methoden dienen die Lernverfahren der Lösung technischer Problemstellungen, sodass sie als Technologie zu bezeichnen sind. Vor diesem Hintergrund findet im weiteren Verlauf auch der Begriff der **ML-Technologie** Verwendung. Die Verfahren stellen die Grundlage für die Entwicklung von darauf basierenden Artefakten in Form von Lernenden Systemen bzw. ML-Anwendungen dar, bei denen es sich definitionsgemäß um Technik handelt. Entgegen dieser klassischen Trennung folgt die vorliegende Arbeit dem integrierten Technologieverständnis, weshalb im weiteren Verlauf auch häufig die beiden Begriff synonym verwendet werden.

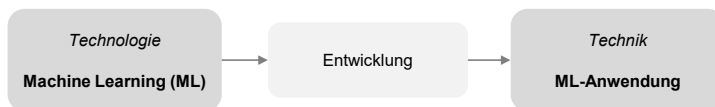


Abbildung 24: Begriffsabgrenzung von ML und ML-Anwendungen³⁸⁸

Wie die Definition in Kapitel 2.4.2.4 zeigt, können Lernende Systeme entsprechend ihres Erscheinungsbildes entweder primär als hardwareseitige Artefakte zur Verrichtung physischer Tätigkeiten, u. a. in Form von Maschinen und Robotern, oder primär als Softwaresysteme zur Verwendung in Informationsprozessen gestaltet werden. Im Rahmen der vorliegenden Arbeit wird der Einsatz von Systemen für Planungs-, Steuerungs- und Kontrollaktivitäten in der Logistik untersucht, welche unter dem Begriff des **Logistikmanagements** zusammengefasst werden. Vor diesem Hintergrund handelt es sich bei den betrachteten Artefakten allgemein um Softwaresysteme, welche als Entscheidungstechnik zur Lösung spezifischer Probleme in Unternehmen eingesetzt werden und daher auch als **Anwendungssysteme** zu betrachten sind.

³⁸⁷ Vgl. Goodfellow et al. (2014), S. 1 ff. Eine Erklärung der GAN erfolgt in Kapitel 4.4.1.

³⁸⁸ Eigene Darstellung

Dies führt zu der verwendeten Wortschöpfung der „ML-Anwendungen“ in der Arbeit. Diese setzen sich grundsätzlich aus Anwendungssoftware in Form eines oder mehrerer **ML-Modelle** sowie aus weiteren Soft- und Hardwarekomponenten zusammen. Dazu gehören neben Komponenten zur Aufnahme, Speicherung und Verarbeitung der benötigten Daten u. a. auch die Infrastruktur zur Ausführung der Systeme sowie Komponenten für etwaige weitere Funktionen, wie eine visuelle Ausgabe oder Ausführung der Ergebnisse.³⁸⁹ Die Ausprägung und der Umfang der einzelnen Komponenten ist abhängig vom jeweiligen Anwendungsfall.

Die als Anwendungsbereich für die ML-Anwendungen vorgesehenen Aktivitäten beziehen sich auf die gesamte industrielle Logistikkette, wofür unter Verwendung der SCP-Matrix eine Ableitung wesentlicher Prozesse in Kapitel 2.2.2 erfolgte. Ausgehend von diesen „Referenzprozessen“, bei denen es sich primär um Aktivitäten zur Ermittlung und Auswahl von geeigneten Handlungsalternativen handelt, z. B. das Treffen geeigneter Entscheidungen für die Maschinensteuerung, werden auch die jeweils vorgelagerten Aktivitäten zur Informationsbeschaffung in der Arbeit betrachtet. Dies umfasst u. a. die Detektion von Problemen, die Bestimmung der Ausprägungen für relevante Einflussfaktoren sowie die Ermittlung voraussichtlicher Auswirkungen von Handlungsalternativen. Dabei wird dem in Kapitel 2.3.2 dargestellten Prozessverständnis von Entscheidungen gefolgt, welches ebenfalls als Referenzstruktur fungiert und Entscheidungen als Bündel von Teilproblemen betrachtet, für die mehrere Teilentscheidungen notwendig sind. Vor diesem Hintergrund wird in Bezug auf die betrachteten Aktivitäten daher auch der Begriff der **logistischen Entscheidungsprozesse** verwendet.

Entsprechend der inhärenten Eigenschaften der Logistik und unterstützt durch äußere Entwicklungen weisen die Entscheidungsprozesse häufig eine ausgeprägte Komplexität auf, die sich u. a. in Form vieler vernetzter und dynamische Parameter, multikriterieller und konfliktärer Zielsetzungen, einer hohen Unsicherheit und eines geringen Zeitkontingents äußert. Ausgehend von den damit verbundenen Herausforderungen bei einer manuellen Ausführung sowie bei einer Unterstützung durch bestehende Entscheidungstechniken, die jeweils in ihren Problemlösungsfähigkeiten beschränkt sind, soll mit dem Einsatz von ML-Anwendungen eine Verbesserung für die Unternehmen einhergehen. Dies kann zum einen durch eine Bereitstellung von Informationen für den Entscheidungsträger realisiert werden. Zum andern ist aber auch festzustellen, dass ML eine bedeutende technische Grundlage zur autonomen Ausführung von Prozessen darstellt. Bei beiden Realisierungsformen liegen ausgeprägte **Wirkungsbeziehungen zwischen den ML-Anwendungen und den Organisationsmitgliedern** vor, die in Form einer direkten Interaktion mit den jeweiligen Nutzern bestehen, aber sich auch indirekt u. a. durch die Gestaltung der Arbeitsorganisation und die Entwicklung der Systeme äußern.

Über die genannten Zusammenhänge hinaus wirken weitere unternehmensinterne und -externe Faktoren direkt oder indirekt auf ML-Anwendungen ein, indem sie bspw. die Vorausset-

³⁸⁹ Vgl. Sculley et al. (2015), S. 3 ff.

zungen für deren Einsatz schaffen, aber mitunter auch Restriktionen darstellen. Die Gesamtheit dieser Faktoren wird als **Umfeld der Anwendungen** bezeichnet und umfasst neben den Organisationsmitgliedern u. a. auch technische Faktoren, wie die vorhandene IT-Infrastruktur und andere bestehende Anwendungen, sowie rechtliche, ethische und politische Rahmenbedingungen.³⁹⁰

Bei einer Zusammenführung dieser Erkenntnisse lassen sich ML-Anwendungen im Logistikmanagement aus systemtechnischer Sicht als **IT-Systeme** modellieren, die aus einer technischen, prozessualen und sozialen Dimension bestehen, welche wiederum durch weitere Umfeldbedingungen beeinflusst werden (Abbildung 25). Gemäß den Erkenntnissen aus der Adoptionsforschung sind für die Gestaltung eines erfolgreichen Einsatzes von IT-Technologien relevante Faktoren zu all diesen Dimensionen zu ermitteln und anschließend durch geeignete Maßnahmen auf anwendungsbezogener und gesamtorganisatorischer Ebene zu adressieren, wobei zusätzlich die damit verbundenen Wechselwirkungen zu berücksichtigen sind.

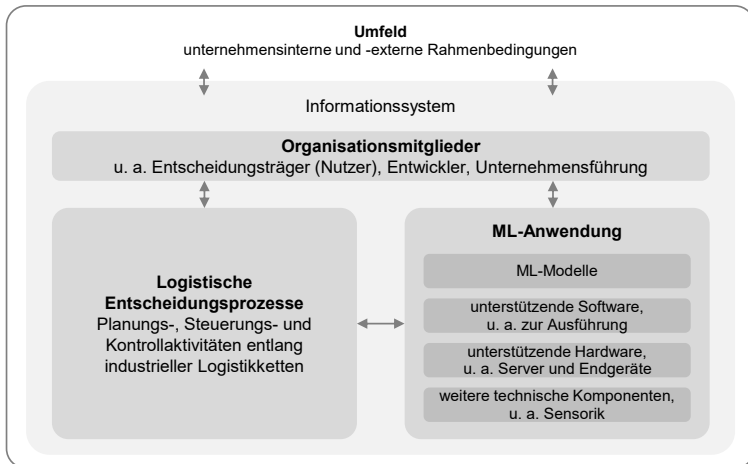


Abbildung 25: Systemtechnisches Modell von ML-Anwendungen im Logistikmanagement³⁹¹

³⁹⁰ Vgl. Jordan, Mitchell (2015), S. 256

³⁹¹ Eigene Darstellung

3 Forschungsmethodik

Gemäß den Ausführungen in Kapitel 1.1 ist das adressierte Forschungsfeld der vorliegenden Arbeit bisher nur im geringen Maße erschlossen. Zur Gewinnung erster Erkenntnisse und Theorien für die Beantwortung der weiteren Forschungsfragen wird daher ein **explorativer Forschungsansatz** gewählt. Im Gegensatz zum explanativen und deskriptiven Ansatz, bei denen bereits Hypothesen und/oder ein vergleichsweise umfangreiches Vorwissen bestehen, eignen sich explorative Untersuchungen für neuartige, bisher wenig durchdrungene Untersuchungsfelder.³⁹² Für die Erhebung und Analyse der benötigten Daten stehen im Rahmen der explorativen Forschung mehrere Methoden zur Verfügung, die unter Berücksichtigung des jeweiligen wissenschaftlichen Stands und des darauf basierenden Forschungsziels zu wählen sind³⁹³. Zur Absicherung der Güte und der Nachvollziehbarkeit der erzielten Ergebnisse bedarf es einer detaillierten Darstellung des jeweiligen methodischen Vorgehens.³⁹⁴ Dieser **Methodenkontrolle** soll mit den Ausführungen im vorliegenden Kapitel Rechnung getragen werden.

Die gewählte Methodik ist grundsätzlich in Bezug auf die Strategien im Umgang mit den benötigten Daten zu unterscheiden. Zum einen konnte auf Sekundärdaten aus wissenschaftlichen Veröffentlichungen zurückgegriffen werden, welche auf geeignete Weise zur Erzielung neuer Erkenntnisse verarbeitet wurden. Dies betraf die Beantwortung eines Teilaspektes der zweiten sekundären Forschungsfrage zur Ermittlung der Anwendungsmöglichkeiten von ML im Logistikmanagement, deren Ergebnisse als wichtiges Bezugsobjekt für die weiteren Untersuchungen fungieren. Hierfür wurde eine **Typenbildung** vorgenommen, die auf Basis einer systematischen Analyse bestehender Literatur eine rechnergestützte Clusteranalyse umfasste (Kapitel 3.1). Zum anderen mussten in Ermangelung bestehender Informationen eigenständig Daten aus der Praxis erhoben werden. Diese sog. Primärdatenerhebung³⁹⁵ wurde für Teile der zweiten bis fünften sekundären Forschungsfrage durchgeführt, um u. a. Auswirkungen, den Praxisstand, die Anforderungen und mögliche Umsetzungsmaßnahmen von ML-Anwendungen im Logistikmanagement zu ermitteln. Dies erfolgte im Rahmen einer mehrstufigen **empirischen Untersuchung** unter Einbindung von Unternehmensvertretern (Kapitel 3.2).

3.1 Typenbildung

Für die Beantwortung der dritten sekundären Forschungsfrage wurde mit der Typenbildung eine Methode zur Systematisierung der Anwendungsmöglichkeiten von ML im Logistikmanagement gewählt, welche durch eine Zusammenfassung von ähnlichen Objekten im Rahmen eines strukturierten Vorgehens ein generalisiertes Abbild der Realität erzeugt und dabei deren

³⁹² Vgl. Bortz, Döring (2006), S. 50

³⁹³ Vgl. Bortz, Döring (2006), S. 29 f., 49; Ulrich (1981), S. 21; Yin (2009), S. 8

³⁹⁴ Vgl. Mayring (2002), S. 29

³⁹⁵ Vgl. Kornmeier (2007), S. 158

Komplexität ohne Verlust der Aussagekraft reduziert³⁹⁶. Die Typenbildung eignet sich insbesondere für die Systematisierung bisher unerforschter Gebiete³⁹⁷ und wurde bereits mehrfach im Technologiekontext eingesetzt, u. a. zur Typisierung von technologiebezogenen Unternehmensstrategien und Projekten sowie von Anwendungen³⁹⁸. In der vorliegenden Untersuchung wurde die Bildung von **Realtypen**³⁹⁹ verfolgt, welche „*empirische Verteilungen und Korrelationen möglichst wirklichkeitsgetreu*“ darstellen.⁴⁰⁰ Als Abbild der Realität lassen sich auf Basis dieser Typen Hypothesen zu tieferliegenden Phänomenen der jeweiligen Bezugsobjekte ableiten⁴⁰¹, was eine zusätzliche Analyse und Interpretation der Typen erfordert.⁴⁰²

Der gewählte Ansatz erfordert die **Einbeziehung von empirischem Datenmaterial**, welches die zu typisierenden Bezugsobjekte möglichst treffend in Hinblick auf die jeweilige Zielstellung beschreibt.⁴⁰³ Im vorliegenden Fall beziehen sich die benötigten Daten auf die Eigenschaften von ML-Anwendungen, wobei die betrachteten Systeme zudem das gegenwärtige Anwendungsspektrum möglichst gut repräsentieren sollen. Die benötigten Daten mussten daher in einem ersten Schritt generiert werden, wofür eine Charakterisierung bestehender ML-Anwendungen anhand geeigneter Merkmale vorgenommen wurde. Die Informationen zu bestehenden Anwendungen wurden durch einen Rückgriff auf Sekundärdaten in Form von wissenschaftlichen Veröffentlichungen bezogen, deren Identifikation im Rahmen einer **systematischen Literaturanalyse** (SLA) erfolgte. In einem zweiten Schritt wurden die ermittelten Eigenschaften in Form der Merkmalsausprägungen für die Durchführung einer **Clusteranalyse** genutzt. Mittels einer anschließenden Charakterisierung, Bewertung und Interpretation der resultierenden Typen konnten Aussagen zum aktuellen und zukünftigen Anwendungsspektrum im Untersuchungsfeld getroffen werden, wodurch das gewählte Vorgehen neben seiner deskriptiven Funktion auch einen **erklärenden und gestaltenden Beitrag für die Praxis** leistet⁴⁰⁴. Die Aktivitäten der Typenbildung lassen sich daher in Bezug auf die eingesetzten Methoden in zwei übergeordnete Schritte einteilen, welche in Abbildung 26 dargestellt sind.

³⁹⁶ Vgl. Kluge (1999), S. 23

³⁹⁷ Vgl. Kuckartz (2010), S. 553 ff.; Mayring (2002), S. 131 f.

³⁹⁸ Vertreter hierfür sind u. a. Renz (2004); Braunschmidt, Hauschildt (2005); Rhensius (2010).

³⁹⁹ Typen werden je nach Erhebungsmethode auch als Gruppen oder Cluster bezeichnet. Vgl.

Kuckartz (2010), S. 556. Im weiteren Verlauf erfolgt eine synonyme Begriffsverwendung.

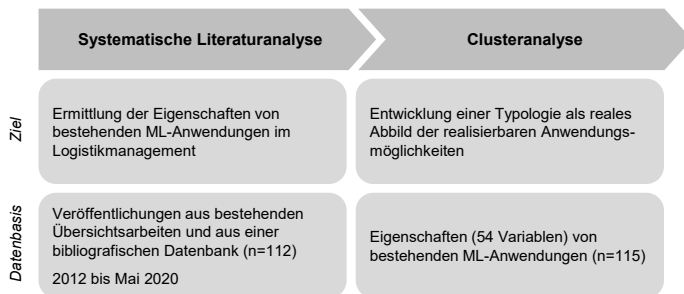
⁴⁰⁰ Kluge (1999), S. 59

⁴⁰¹ Vgl. Kluge (1999), S. 43 ff.

⁴⁰² Vgl. Kelle, Kluge (2010), S. 90

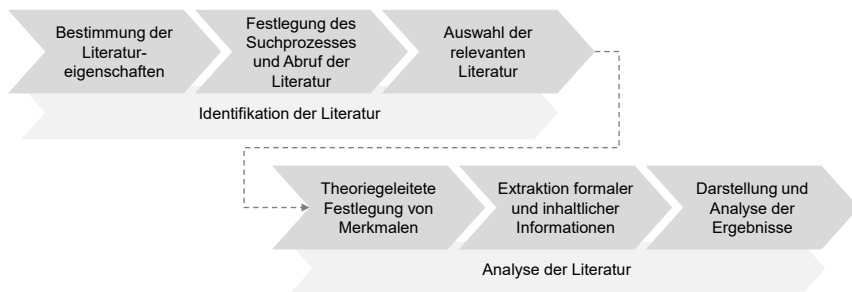
⁴⁰³ Vgl. Kluge (1999), S. 266

⁴⁰⁴ Vgl. Welter (2006), S. 114; Kuckartz (2010), S. 556

Abbildung 26: Methoden der Typenbildung⁴⁰⁵

3.1.1 Systematische Literaturanalyse

Zur Erfassung des gegenwärtigen Spektrums von ML-Anwendungen im Logistikmanagement wurde eine **systematischen Literaturanalyse** durchgeführt, welche eine Identifizierung der wichtigsten Publikationen⁴⁰⁶ und deren Erkenntnisse zu einem Untersuchungsbereich im Rahmen eines strukturierten und damit wiederholbaren Such- und Analyseprozesses ermöglicht.⁴⁰⁷ Die gewählte Gestaltung der SLA orientierte sich am Vorgehen von *Tranfield et al. (2003)* und kann in die zwei wesentlichen Phasen der Identifikation und Analyse der Literatur eingeteilt werden (siehe Abbildung 28).

Abbildung 27: Vorgehen bei der systematischen Literaturanalyse⁴⁰⁸

In der ersten Phase wurden einleitend geeignete Auswahlmerkmale in Form von Inklusionskriterien definiert, welche alle gleichzeitig von den identifizierten Veröffentlichungen für eine weitere Betrachtung erfüllt sein mussten. Ausgehend von einer Beschränkung auf **wissenschaftliche Literatur ab dem Jahre 2012** mussten die Artikel Informationen zu mindestens einem Anwendungsfall von ML im Logistikmanagement enthalten und in englischer Sprache

⁴⁰⁵ Eigene Darstellung

⁴⁰⁶ Im weiteren Verlauf wird hierfür synonym der Begriff der Artikel verwendet.

⁴⁰⁷ Vgl. Tranfield et al. (2003), S. 209

⁴⁰⁸ Eigene Darstellung in Anlehnung an Tranfield et al. (2003), S. 215

verfasst sein. Zur Sicherstellung eines möglichst breiten Spektrums an ML-Anwendungen erfolgte der Suchprozess auf zwei Wegen. Zum einen wurden potenziell geeignete Veröffentlichungen anhand von bestehenden **Übersichtsarbeiten** (Literature Reviews) ermittelt, welche im weitesten Sinne gleichzeitig der Logistik und ML zuzuordnen waren. Diese Vergrößerung des Betrachtungsbereiches im Vergleich zum vorliegenden Untersuchungsfeld führte zu einer Identifikation von insgesamt 16 Übersichtsarbeiten⁴⁰⁹. Nach deren inhaltlicher Analyse und Bewertung anhand mehrerer Kriterien wurden mit *Agarwal, Jayant (2019)*, *Ni et al. (2019)*, *Giri et al. (2019)* und *Sharma et al. (2020)* vier Arbeiten abgeleitet, aus denen im Rahmen eines übergreifenden Abgleiches 397 potenziell relevante Artikel extrahiert werden konnten. Zum anderen wurden Artikel auf der **bibliografischen Datenbank Business Source Complete** des Informationsanbieters EBSCO durchsucht. Hierzu wurde ein individuell entwickelter Suchstring eingesetzt, der sich aus einer Kombination von relevanten Schlüsselwörtern zusammensetzt und eine Reproduzierbarkeit der Suche ermöglicht⁴¹⁰. Um möglichst das gesamte Spektrum des Untersuchungsfeldes abzudecken, wurden hierbei auch Begriffssynonyme und Wörter mit Kontextbezügen aufgenommen. Nach iterativer Überprüfung verschiedener Kombinationen anhand der jeweiligen Ergebnisse wurde folgender String festgelegt:

("artificial intelligence" OR "machine learning" OR "deep learning" OR "reinforcement learning" OR "neural networks") AND ("logistics" OR "supply chain" OR "SCM" OR "transport*" OR "warehouse*" OR "production" OR "manufacturing" OR "procurement") AND ("use case*" OR "implement*" OR "application*" OR "utilization" OR "case stud*")*

Die Suche auf der Datenbank bezog sich auf vier Informationsbereiche zu den Veröffentlichungen: Titel und Abstract sowie die vom jeweiligen Autor vorgeschlagenen Schlagwörter (Keywords) und die von EBSCO erzeugten Schlagwörter (Subject Terms). Insgesamt wurden dadurch weitere 960 Artikel identifiziert. Nach Kombination der Ergebnisse der beiden Suchverfahren und der Entfernung von Duplikaten lagen insgesamt 1.357 Artikel vor, die anschließend in Bezug auf die Inklusionskriterien zusammen mit einem weiteren Wissenschaftler zur Vermeidung einer subjektiven Verzerrung überprüft wurden (siehe Abbildung 28). Dies führte zu einer finalen Ergebnismenge von 112 relevanten Veröffentlichungen⁴¹¹, aus denen wiederum insgesamt **115 ML-Anwendungen** im Logistikmanagement⁴¹² extrahiert werden konnten.

⁴⁰⁹ Eine Übersicht zu den identifizierten Literature Reviews findet sich in Tabelle 33 im Anhang. Deren detaillierte Analyse erfolgt in Kapitel 4.1.2.

⁴¹⁰ Vgl. Tranfield et al. (2003), S. 215

⁴¹¹ Eine Charakterisierung der Veröffentlichungen anhand bibliografischer Informationen findet sich im Anhang beginnend ab Abbildung 99.

⁴¹² Entsprechend des abweichenden kontextbezogenen Einsatzes von Anwendungen wird im weiteren Verlauf auch der Begriff des Anwendungsfalls (Use Case) verwendet.

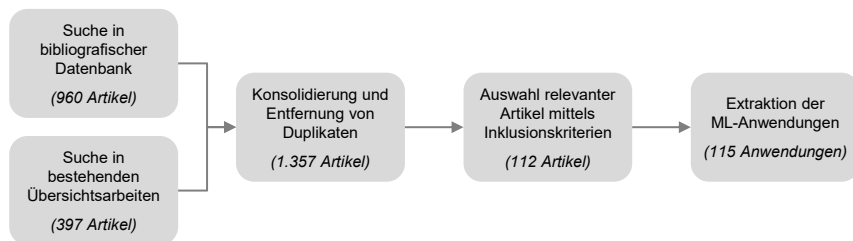


Abbildung 28: Vorgehen und Ergebnisse der Identifikation von ML-Anwendungen⁴¹³

In der zweiten Phase wurden die identifizierten Anwendungen analysiert, was einleitend die Ermittlung geeigneter Merkmale zur Extraktion der systemseitigen Eigenschaften beinhaltete. Diese späteren Vergleichsdimensionen müssen die Anwendungen hinsichtlich etwaiger Gemeinsamkeiten und Unterschiede möglichst gut charakterisieren.⁴¹⁴ Die hierfür notwendige intensive theoretische Auseinandersetzung mit den Betrachtungsobjekten⁴¹⁵ wurde durch die Untersuchungen in Kapitel 2 sichergestellt. Nach iterativer Bestimmung der Merkmale unter Berücksichtigung der Informationssituationen in den Veröffentlichungen wurden die jeweiligen Ausprägungen der Anwendungen erhoben, wobei in den Fällen einer Unsicherheit erneut die Diskussion mit einem weiteren Wissenschaftler erfolgte. Der resultierende Merkmalsraum wurde anschließend unter Nutzung von **Verfahren der deskriptiven Statistik** ausgewertet und interpretiert. Die diesbezüglichen Erkenntnisse stellten eine wichtige Grundlage für die anschließende Typen- und Theoriebildung dar, indem hierdurch relevante Zusammenhänge innerhalb und zwischen den Typen entdeckt werden konnten, u. a. in Form einer Verteilung bestimmter Merkmalsausprägungen.

3.1.2 Clusteranalyse

Für die Durchführung der Typenbildung stehen grundsätzlich mehrere Möglichkeiten zur Verfügung, welche von qualitativen, heuristischen Ansätzen bis hin zu quantitativen, rechnergestützten Verfahren reichen.⁴¹⁶ Aufgrund der Komplexität des vorliegenden Merkmalsraums zur Charakterisierung von ML-Anwendungen, welche sich aus dem breiten Spektrum der prozessualen und technischen Dimension des Untersuchungsfeldes sowie der Vielzahl an berücksichtigten Anwendungen ergibt, bestand bei einer manuellen Identifikation der Typen das Risiko von Fehleinschätzungen. Vor diesem Hintergrund wurde mit der **Clusteranalyse** ein quantitatives, rechnergestütztes Verfahren gewählt, welches eine simultane Berücksichtigung von vielen Merkmalen und Betrachtungsobjekten erlaubt⁴¹⁷. Wie die Ausführungen in Kapitel

⁴¹³ Eigene Darstellung

⁴¹⁴ Vgl. Kelle, Kluge (2010), S. 91 ff.

⁴¹⁵ Vgl. Kluge (1999), S. 266

⁴¹⁶ Vgl. Kuckartz (2010), S. 558

⁴¹⁷ Vgl. Kluge (1999), S. 255

2.4.3.3 zeigen, erfolgt die Bildung der Typen bzw. Cluster in diesem Fall durch das automatische Erkennen von Zusammenhängen in vorgegebenen Daten⁴¹⁸, wobei den jeweiligen Algorithmen keinerlei Zusatzinformationen bereitgestellt werden, weshalb die Clusteranalyse im Kontext von ML dem Lerntyp des **Unsupervised Learning** zugeordnet wird. Durch die angestrebte interne Homogenität der Cluster werden besondere Eigenschaften und Ziele der Objekte hervorgehoben, wohingegen die externe Heterogenität Differenzen der Betrachtungsobjekte aufzeigt.⁴¹⁹ Anders als bei qualitativen Verfahren ist mittels der Clusteranalyse auch die optimale Typenanzahl durch objektive Kriterien bestimmbar.⁴²⁰ Zudem erlaubt das Verfahren einen eindeutigen Bezug zum einbezogenen Datenmaterial, um wichtige Phänomene, wie z. B. Unterschiede zwischen den Typen, zu erschließen.⁴²¹ Die Umsetzung dieser Methode erfolgte im vorliegenden Fall in Anlehnung an das Vorgehen nach *Backhaus et al. (2016)*, welches sich durch eine Iteration der einzelnen Schritte zur Identifikation der optimalen Typen auszeichnet (siehe Abbildung 29).




Abbildung 29: Vorgehen bei der Clusteranalyse⁴²²

Die im Rahmen der SLA ermittelten Merkmalsausprägungen stellten die Variablen für die Clusteranalyse dar. Diese wurden vorab in eine geeignete Datenstruktur überführt und hinsichtlich ihrer inhaltlichen Eignung überprüft. Hierzu gehörte u. a. eine Eliminierung bzw. Transformation von Merkmalen mit einer hohen linearen Abhängigkeit in Form eines Korrelationskoeffizienten von $r \geq 0,9$.⁴²³ Zur Unterstützung dieses Schrittes wurden Korrelationsmatrizen generiert, welche sich für die Überprüfung der paarweisen Korrelation eignen⁴²⁴. Finale Entscheidungen zur Merkmalsauswahl konnten jedoch erst im Rahmen der Durchführung des Gruppierungsvorgangs getroffen werden. Für das damit verbundene Verfahren, einschließlich des **Proximitätsmaßes**, welches im Falle von deterministischen Verfahren die Logik zur Berechnung der Ähnlichkeiten oder Distanzen zwischen Bezugsobjekten vorgibt, stehen mehrere Ansätze zur Verfügung⁴²⁵. Unter Berücksichtigung des vorliegenden Datenmaterials wurde mit dem **Ward-Algorithmus**⁴²⁶ ein hierarchisch-agglomeratives Verfahren gewählt, welches

⁴¹⁸ Vgl. Backhaus et al. (2016), S. 455

⁴¹⁹ Vgl. Kluge (1999), S. 29

⁴²⁰ Vgl. Kuckartz (2010), S. 561

⁴²¹ Vgl. Kluge (1999), S. 252

⁴²² Eigene Darstellung in Anlehnung an Backhaus et al. (2016), S. 513

⁴²³ Vgl. Backhaus et al. (2016), S. 511

⁴²⁴ Vgl. Eckstein (2014), S. 390

⁴²⁵ Übersichten hierzu finden sich in Eckstein (2014), S. 409; Backhaus et al. (2016), S. 476.

⁴²⁶ Die Ward-Methode geht auf die Arbeit von Ward (1963) zurück.

gleichzeitig die euklidische Distanz als inhärentes Proximitätsmaß enthält. Als Varianz-Methode zielt der Ward-Algorithmus auf die Zusammenfassung von Objekten zu Clustern unter Minimierung der Varianz der einzelnen Distanzen (Fehlerquadratsumme) ab.⁴²⁷ Im Vergleich zu anderen Verfahren lässt sich beim Ward-Algorithmus eine Bildung sehr homogener Cluster feststellen⁴²⁸, sodass dieser als „verlässlicher Algorithmus“ beschrieben wird⁴²⁹ und daher eine breite Anwendung findet⁴³⁰.

Für die Durchführung der Clusteranalyse wurde anschließend unter Nutzung der Programmiersprache **Python** ein Algorithmus implementiert. Hierzu erfolgte ein Rückgriff auf verschiedene Bibliotheken der Entwicklungsumgebung, u. a. auf die Bibliothek **scikit-learn**, welche eine vordefinierte Klasse zur Anwendung des Ward-Algorithmus bereitstellte. Unter Abwägung der Erzielung möglichst homogener Cluster und der Sicherstellung einer praktikablen inhaltlichen Auswertung⁴³¹ wurde dem Algorithmus zusätzlich eine Ober- und Untergrenze für die zu betrachtende Clusteranzahl vorgegeben. Im Rahmen einer iterativen Durchführung des Gruppierungsprozesses, welcher u. a. zur Anpassung der Variablen führte, konnte die optimale Clusteranzahl ermittelt werden. Hierzu wurden mit dem **Dendrogramm**, welches die Zusammenfassung der Bezugsobjekte zu Clustern in mehreren Schritten anhand des gewählten Proximitätsmaßes verdeutlicht⁴³², und dem **Dunn-Index** (DI)⁴³³, welcher die Kompaktheit und Abgrenzbarkeit der resultierenden Cluster aufzeigt⁴³⁴, zwei technische Hilfsmittel eingesetzt. Neben einer parallel zum Gruppierungsvorgang stattfindenden Analyse für die Festlegung der Clusteranzahl wurden die finalen Cluster im Anschluss charakterisiert.

3.2 Empirische Untersuchung

Zur Beantwortung von Teilen der zweiten bis fünften sekundären Forschungsfrage bedurfte es einer Erhebung von Primärdaten aus der Praxis. Mittels eines geeigneten Methodeneinsatzes sollten hierbei die benötigten Informationen von Unternehmensvertretern in Form einer aussagekräftigen Stichprobe aufgenommen und dadurch repräsentative Aussagen zur Theoriebildung abgeleitet werden. Für die empirische Informationserhebung stehen verschiedene Methoden zur Verfügung, die grundsätzlich in qualitative und quantitative Methoden zu unterscheiden sind. Im Falle von gering erschlossenen Untersuchungsfeldern eignen sich v. a. **qualitative Methoden**, da diese eine breite Analyse aus verschiedenen Perspektiven sowie eine flexible Reaktion auf Situationen ermöglichen und damit zur Aufdeckung tieferliegender Phänomene beitragen.⁴³⁵ Dagegen sind die Erhebungsbedingungen bei **quantitativen Methoden**

⁴²⁷ Vgl. Wentura, Pospeschill (2015), S. 170; Backhaus et al. (2016), S. 485

⁴²⁸ Vgl. Kluge (1999), S. 249

⁴²⁹ Wentura, Pospeschill (2015), S. 171

⁴³⁰ Vgl. Eckstein (2014), S. 416

⁴³¹ Vgl. Backhaus et al. (2016), S. 494

⁴³² Vgl. Everitt (2011), S. 72

⁴³³ Der Dunn-Index geht auf die Arbeit von Dunn (1973) zurück.

⁴³⁴ Vgl. Halkidi et al. (2001), S. 130

⁴³⁵ Vgl. Flick et al. (2010), S. 17, 25

stärker fixiert, was einerseits die situative Einflussnahme einschränkt, aber andererseits statistische Auswertungen des resultierenden Datenmaterials, u. a. für Vergleiche und Bewertungen, erlaubt.⁴³⁶

Im vorliegenden Fall wurde eine methodische Triangulation in Form eines **Mix-Method-Design**⁴³⁷ gewählt, bei der sowohl qualitative als auch quantitative Methoden zur gezielten Nutzung der Stärken beider Ansätze zum Einsatz kamen. Es wurde dazu ein in der Forschung anerkanntes Vorgehen zur sequenziellen Verbindung der Methoden realisiert⁴³⁸, welches eine inkrementelle Ergänzung der jeweiligen Ergebnisse vorsah. Hierbei erfolgte zum einen die Überprüfung von Ergebnissen, die im Rahmen einer qualitativen Forschung auf Basis einer **Gruppendiskussion** entstanden sind, mittels einer quantitativen Methode in Form einer **Onlinebefragung**. Zum anderen wurden die statistischen Ergebnisse aus dieser Onlinebefragung unter Verwendung einer qualitativen Methode in Form von **Experteninterviews** und daraus hervorgehenden **Fallstudien** interpretiert und ergänzt. Die Datenbasis zu diesen drei Befragungstechniken, welche zusammenfassend in Abbildung 30 dargestellt sind, entstammte den Aussagen von verschiedenen Praxisvertretern, welche entweder bestehende bzw. potenzielle Anwender oder Anbieter von ML-Anwendungen im Logistikmanagement darstellen.




Abbildung 30: Mixed-Method-Design der empirischen Untersuchung⁴³⁹

⁴³⁶ Vgl. Flick et al. (2010), S. 25; Bortz, Döring (2006), S. 296 f.

⁴³⁷ Vgl. Kelle (2019), S. 164

⁴³⁸ Vgl. Flick et al. (2010), S. 25 f.; Kelle (2019), S. 166 ff.

⁴³⁹ Eigene Darstellung

3.2.1 Gruppendiskussion

Für die Ermittlung von Anforderungen an den Einsatz von ML-Anwendungen im Logistikmanagement sollten unterschiedliche Meinungen und Voraussetzungen von Unternehmen berücksichtigt werden, um hieraus repräsentative Aussagen ableiten zu können. Zur Erhebung dieser Informationen wurde als erster Schritt der empirischen Untersuchung eine Gruppendiskussion durchgeführt. Diese qualitative Methode sieht eine **mündliche Befragung** von Gruppen vor und ermöglicht die geleitete Aufnahme unterschiedlicher Meinungen zu einer Fragestellung.⁴⁴⁰ Neben den Diskussionsergebnissen werden hierbei hilfreiche Motive, Probleme und Argumente der einzelnen Teilnehmer sichtbar, die zum individuellen Meinungsbild führen.⁴⁴¹ Aufgrund des offenen Diskurses und der Gewinnung von Hintergrundinformationen eignen sich Gruppendiskussionen insbesondere für explorative Untersuchungen zu komplexen Fragestellungen.⁴⁴² Vor diesem Hintergrund und der Möglichkeit zur gegenseitigen Ideenaneregung der Teilnehmer wurde die Gruppenbefragung einer Einzelbefragung für das adressierte Thema vorgezogen. Entsprechend ihres Potenzials zur simultanen Erfassung unterschiedlicher Sichtweisen stellt sie eine anerkannte Methode zur Erhebung von Anforderungen an Softwaresysteme dar.⁴⁴³ Unter Berücksichtigung der Empfehlungen von *Lamnek (2005)*⁴⁴⁴ orientiert sich das gewählte Design der Befragung an dem Vorgehen von *Mayring (2002)*, welches in Abbildung 31 dargestellt ist.

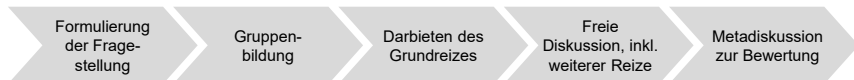


Abbildung 31: Vorgehen bei der Gruppendiskussion⁴⁴⁵

An der durchgeführten Gruppendiskussion waren **20 Praxisvertreter** mit Leitungsfunktionen in der Logistik beteiligt. Diese gehörten verschiedenen Unternehmen aus Industrie, Handel sowie Logistik- und IT-Dienstleistung an, deren Aktivitäten sich wiederum auf mehrere Marktsegmente erstreckten, u. a. in Form der Automobil-, Elektronik-, Chemie- und Pharmaindustrie. Die Teilnehmer wurden zu Beginn in drei feste Gruppen eingeteilt. Dabei wurden jeder Gruppe einzelne Vertreter von verschiedenen Unternehmensbranchen und -größen zugeordnet, um ein möglichst breites Spektrum an Sichtweisen abzubilden. Zudem erhielt jede Gruppe einen Moderator, der die Zeiteinhaltung kontrollierte, methodische Fragen beantwortete und Aussagen der Gruppenmitglieder dokumentierte. Neben den organisatorischen Aufgaben unterstützte

⁴⁴⁰ Vgl. Lamnek (2005), S. 35

⁴⁴¹ Vgl. Lamnek (2005), S. 33 f.

⁴⁴² Vgl. Lamnek (2005), S. 71

⁴⁴³ Vgl. Balzert (2009), S. 507

⁴⁴⁴ Vgl. Lamnek (2005), S. 89 ff., 130 ff.

⁴⁴⁵ Eigene Darstellung in Anlehnung an Mayring (2002), S. 79

dieser Rückgriff auf die **Moderationsmethode** den Abbau von Hemmnissen bei den Teilnehmern zur Meinungsäußerung, indem partiell anregende Impulse und Ansprachen durch die Moderatoren erfolgten⁴⁴⁶.

Mittels einer thematischen Einführung und einer Abgrenzung des Untersuchungsfeldes durch den Autor wurde die Gruppendiskussion eingeleitet. Dies diente der Schaffung eines einheitlichen Verständnisses und der Klärung von inhaltlichen und methodischen Fragen. Zudem wurden die Teilnehmer mit einem Grundanreiz in Form einer Vision zur zukünftigen Gestaltung der Logistik unter Nutzung von ML-Anwendungen in Entscheidungsprozessen konfrontiert. Um das Befragungsziel effektiver erschließen zu können, wurde die Befragung in zwei Teilschritte mit separaten Zielstellungen strukturiert, welche von allen Gruppen durchlaufen wurden. Die erste Phase diente der **gruppeninternen Diskussion**, bei der zu Beginn eine isolierte Generierung von Ideen zu individuellen Anforderungen durch jedes Gruppenmitglied erfolgte. Anschließend wurden diese Ideen mit den anderen Mitgliedern der jeweiligen Gruppe diskutiert und strukturiert. Darauf aufbauend fand eine Priorisierung der Ideen in Hinblick auf die maximal fünf wichtigsten Anforderungen innerhalb der Gruppen statt. In der zweiten Phase erfolgte eine **Metadiskussion** der erzielten Ergebnisse in einem gruppenübergreifenden Kontext. Dazu wurden nacheinander von allen Gruppen die jeweils wichtigsten Anforderungen unter Nennung von Begründungen und anderen Zusatzinformationen präsentiert. Nach jeder Vorstellung sollten die jeweils anderen Gruppen ihre Einschätzung zu den Ergebnissen geben, sodass abschließend eine Diskussion zu allen gruppenbezogenen Sichtweisen entstand.

Die Dokumentation der Ideen und Erkenntnisse erfolgte durch die Teilnehmer anhand von bereitgestellten Vordrucken, welche nachträglich dem Autor zur Verfügung gestellt wurden. Zusammen mit den Mitschriften der Moderatoren, welche u. a. Argumentationsketten und Beispiele zur Veranschaulichung der Anforderungen aus den Unternehmen enthielten, stellten sie die Grundlage für die anschließende Ergebnisauswertung dar. Dazu wurden die genannten Einzelanforderungen mit den dazugehörigen Hintergrundinformationen in eine einheitliche Struktur überführt und analysiert, was auch eine Ermittlung von inhaltlichen Zusammenhängen beinhaltet. Im Rahmen eines iterativen Vorgehens erfolgte eine Systematisierung der Anforderungen anhand von gebildeten Kategorien auf mehreren Ebenen.

3.2.2 Onlinebefragung

Für eine Bewertung der identifizierten Anforderungen und Anwendungsmöglichkeiten sowie der Erhebung des Umsetzungsstands und der Bedeutung von ML-Anwendungen im Logistikmanagement wurde eine schriftliche Onlinebefragung auf Basis eines **standardisierten Fragebogens** durchgeführt, bei der erneut unterschiedliche Rahmenbedingungen von Unternehmen Berücksichtigung finden sollten. Die Eignung der gewählten Befragungsmethode resultierte grundsätzlich aus der Möglichkeit einer präzisen Erfassung von Informationen über eine

⁴⁴⁶ Vgl. Bortz, Döring (2006), S. 320

große Anzahl von Beteiligten mit einer anschließenden quantitativen Auswertung der Ergebnisse⁴⁴⁷. Die spezifische Gestaltung als Online-Format erfolgte aufgrund der Vorteile einer guten Erreichbarkeit von potenziellen Teilnehmern, einer geringen Fehleranfälligkeit bei der Auswertung und vergleichsweise geringer Kosten⁴⁴⁸. Anders als bei der Gruppendiskussion besteht bei einer Onlinebefragung jedoch nicht die Möglichkeit einer Interaktion mit den Beteiligten. Dies stellt zwar eine objektive Beantwortung sicher, kann aber auch zu ungewollten Effekten, z. B. in Form von Fehlinterpretationen, führen.⁴⁴⁹ Vor diesem Hintergrund bedarf es einer hohen Sorgfalt bei der Gestaltung des jeweiligen Fragebogens, was u. a. eine Formulierung möglichst intuitiver Fragen und eine Integration von Plausibilitätsprüfungen umfasst.⁴⁵⁰ Die Gestaltung der durchgeführten Befragung orientierte sich am Vorgehen nach *Forza (2002)*, welches in Abbildung 32 dargestellt ist und die besonderen Anforderungen an die Methode im industriellen Umfeld berücksichtigt.




Abbildung 32: Vorgehen bei der Onlinebefragung⁴⁵¹

Der verwendete Fragebogen bestand aus **14 inhaltlichen Fragen** mit vor- und nachgelagerten Ergänzungen, wobei ausschließlich geschlossene Fragen mit dichotomen Antwortvorgaben und Likert-Skalen formuliert wurden. Einleitend wurden eine Beschreibung und Abgrenzung des Untersuchungsfeldes sowie eine Darlegung des übergeordneten Forschungsziels und der damit verbundenen Nutzung der Antworten vorgenommen. Um einem negativen Einfluss auf das Antwortverhalten der Teilnehmer entgegenzuwirken, wurde an dieser Stelle auf die anonyme Auswertung ohne die Herstellung von Verbindungen zu Unternehmens- und Personennamen hingewiesen. Die nachfolgenden Fragen waren in drei Themenbereiche strukturiert. Der erste Teil umfasste mehrere Fragen zum **Status Quo und zur Bedeutung von ML**, wobei ausgehend von der Logistik in ihrer Gesamtheit eine Differenzierung nach unterschiedlichen logistischen Aufgabenarten stattfand, um etwaige Unterschiede in Bezug auf logistische Entscheidungsprozesse erfassen zu können. Die Abfrage zur Bedeutung fand anhand verschiedener Dimensionen statt, wozu auch eine Bewertung vorgegebener Beweggründe für den Einsatz von ML gehörte. Ausgehend von der Beurteilung des übergreifenden Anwendungsspektrums wurden im zweiten Teil des Fragebogens die auf Basis der Typenbildungen identifizierten **Anwendungsmöglichkeiten** anhand mehrerer Kriterien geprüft, die neben der Relevanz auch den Umsetzungsstand adressierten. Im dritten Teil wurden die in der Gruppenbefragung identifizierten **Anforderungen** bewertet, wozu ähnliche Kriterien vorgegeben

⁴⁴⁷ Vgl. Kromrey (2002), S. 379 f.

⁴⁴⁸ Vgl. Bortz, Döring (2006), S. 260 f.; Wagner-Schelewsky, Hering (2019), S. 789

⁴⁴⁹ Vgl. Kornmeier (2007), S. 164

⁴⁵⁰ Vgl. Bortz, Döring (2006), S. 237; Wagner-Schelewsky, Hering (2019), S. 794

⁴⁵¹ Eigene Darstellung in Anlehnung an Forza (2002), S. 157

waren. Im Anschluss an den inhaltlichen Teil wurden mit der Branche, Größe sowie dem relativen Umsatz und Gewinn mehrere **Hintergrundinformationen** zu den Unternehmen der Teilnehmer erfragt. Zur Überprüfung der Verständlichkeit und der inhaltlichen Güte wurde der Fragebogen vorab von drei Wissenschaftlern getestet und daraufhin iterativ angepasst.

Die Bereitstellung des Fragebogens erfolgte über ein Online-Tool, welches eine automatische Extraktion der Antworten ermöglichte. Der Link zur Umfrage wurde einem großen Personenkreis an Praxisvertretern im logistischen Umfeld über verschiedene Wege bereitgestellt, wozu auch eine gezielte Kontaktaufnahme zu Unternehmen zählte, die – gemäß offiziellen Mitteilungen – bereits über ML-Anwendungen im Logistikmanagement verfügten. In den 23 Tagen der Online-Verfügbarkeit des Fragebogens wurde eine Teilnahme von **74 Personen** verzeichnet. Die durchschnittliche Bearbeitungszeit der Antworten betrug ca. 22 Minuten. Zur Erzielung einer höheren Aussagekraft wurden die ausgefüllten Fragebögen anschließend in Bezug auf mögliche Verzerrungen untersucht, was u. a. eine Analyse des Umfangs und von Inkonsistenzen umfasste. Weiterhin wurden unter Berücksichtigung der Ausführungen von *Keusch (2013)* auch die Bearbeitungszeiten und verschiedene Antwortmuster betrachtet, um Fragebögen mit zu schnellen Antworten (sog. Speeder) und mit immer bzw. abschnittsweise denselben Antworten (sog. Straightliner) zu entfernen. Insgesamt wurden im Rahmen dieser Validierung die Fragebögen von 29 Teilnehmern eliminiert, was zu einem finalen Datensatz von **45 verwertbaren Fragebögen** führte (siehe Tabelle 7).

Grund der Bereinigung	Kriterium	Eliminierte Fragebögen	Veränderung	Anzahl
Ursprünglicher Datensatz				74
Unvollständige	Weniger als zwei Drittel der Fragen beantwortet	25	-34 %	49
Speeder	Weniger als 10 Minuten Bearbeitungszeit	1	-2 %	48
Straightliner	Hoch/sehr hoch ODER gering/sehr gering nie genutzt	1	-2 %	47
	Hoch/sehr hoch ODER gering/sehr gering bei mehr als 90 % der Antworten genutzt	2	-4 %	45
Finaler Datensatz		29	-39 %	45

Tabelle 7: Datenbereinigung der Antworten bei Onlinebefragung

Zur Analyse der Fragebögen wurde der Datensatz in numerische Werte überführt und anschließend unter Verwendung von Methoden der **deskriptiven Statistik**, v. a. in Form uni- und bivariater Analysen, ausgewertet. Neben einer Gesamtbetrachtung beinhaltet dies auch eine Differenzierung der Antworten nach verschiedenen für die Untersuchung relevanten Merkmalen (siehe Abbildung 33), wozu zusätzlich die abgefragten Hintergrundinformationen zu den teilnehmenden Unternehmen herangezogen wurden. Dies betraf eine branchenbezogene Unterscheidung nach Industrieunternehmen und Logistikdienstleistern. Zudem wurde der Umsetzungsstand von ML-Anwendungen betrachtet, was zu einer Unterscheidung der Unternehmen

in sog. Adopter und Non-Adopter führte. Erstere weisen mindestens eine prototypische Anwendung im Logistikmanagement auf. Eine weitere Charakterisierung wurde anhand des wirtschaftlichen Erfolges der Unternehmen vorgenommen, wozu die Eigeneinschätzung der Teilnehmer zum Umsatz und Gewinn sowie zur Mitarbeiterzahl im Branchenvergleich als Indikatoren genutzt wurde. Dies führte zur Differenzierung in sog. Unternehmen des Branchendurchschnitts und in erfolgreiche Unternehmen, wobei letzteres in allen drei Merkmalen eine vergleichsweise hohe Ausprägung ausweisen.




Abbildung 33: Charakterisierung der Datenbasis der Onlinebefragung⁴⁵²

3.2.3 Experteninterviews

Als dritter Schritt der empirischen Untersuchung wurden zur Interpretation der Ergebnisse aus der Onlinebefragung sowie zu deren Ergänzung in Form von geeigneten Maßnahmen für den Einsatz von ML-Anwendungen im Logistikmanagement mehrere Praxisvertreter aus verschiedenen Unternehmen, welche bereits über entsprechende Systeme verfügen, im Rahmen von **problemzentrierten Interviews** befragt. Die Eignung dieser qualitativen Methode für das Untersuchungsziel resultierte aus der Möglichkeit einer offenen Konversation bei einer gleichzeitig strukturierten Erfassung der Inhalte⁴⁵³, was die Erschließung tieferliegender Erklärungen und Zusammenhänge in neuen Untersuchungsfeldern zulässt⁴⁵⁴. Hierbei stellt die Nutzung eines Interviewleitfadens ein wichtiges unterstützendes Instrument dar, da dieser zum einen strukturgebend wirkt und zum anderen die Vergleichbarkeit mehrerer Interviews ermöglicht.⁴⁵⁵ Die Gestaltung der durchgeführten Interviews orientierte sich am Vorgehen von *Mayring (2002)*, welches in Abbildung 34 dargestellt ist.




Abbildung 34: Vorgehen bei den problemzentrierten Interviews⁴⁵⁶

⁴⁵² Eigene Darstellung

⁴⁵³ Vgl. Mayring (2002), S. 67; Hopf (2010), S. 354

⁴⁵⁴ Vgl. Yin (2009), S. 102 ff.

⁴⁵⁵ Vgl. Mayring (2002), S. 70

⁴⁵⁶ Eigene Darstellung in Anlehnung an Mayring (2002), S. 71

Zur teilstandardisierten Durchführung der Interviews wurde ein Leitfaden entwickelt, der offen formulierte Fragen enthielt, die in den Gesprächen um Ad-hoc-Fragen ergänzt wurden. Neben einer thematischen Einführung umfasste dieses Dokument vier Themenbereiche. Nach einer Vorstellung der Personen erfolgte einleitend eine Erfassung der individuellen **Ausgangssituation** des jeweiligen Unternehmens in Bezug auf den Umgang mit ML bzw. mit KI im Allgemeinen, was neben dem Begriffsverständnis und dem strategischen Umgang auch eine Nennung bestehender ML-Anwendungen im Logistikmanagement umfasste. Im Falle von mehreren Lösungen wurde im zweiten Teil jeweils eine **repräsentative Anwendung** für jedes Interview ausgewählt, welche als Bezugsobjekt für weitere Fragen fungierte. Dazu bedurfte es zu Beginn einer detaillierteren Beschreibung dieser Anwendung und des dazugehörigen Projektes, wofür im Leitfaden mögliche Informationsebenen vorgegeben waren, wie der Einsatzbereich, die technische Gestaltung und zukünftige Erweiterungen. Anschließend erfolgte die Erfassung der **Potenziale und Risiken** von ML-Anwendungen im Logistikmanagement, wozu auch ein Bezug zu den Ausprägungen der ausgewählten Anwendung sowie zu den Ergebnissen der Onlinebefragung vorgesehen war. Eine Nutzung dieser Bewertungsergebnisse erfolgte auch im dritten Teil des Fragebogens, indem die ermittelte Bedeutung und der Umsetzungsstand der einzelnen Anforderungen durch die Teilnehmer in Bezug auf die Voraussetzungen im eignen Unternehmen qualifiziert werden sollten. In diesem Kontext wurden auch **Maßnahmen** erfragt, welche die Unternehmen zur Adressierung der jeweils relevanten Anforderungen bereits umsetzen bzw. als sinnvoll erachten, wobei erneut eine anwendungsbezogene und eine -übergreifende Betrachtung vorgesehen war. Der letzte Teil des Leitfadens umfasste Fragen zur zukünftigen Entwicklung von ML im Logistikmanagement, was neben der Darstellung unterstützender und hemmender Faktoren auch **Auswirkungen auf die Ausführung von logistischen Entscheidungsprozessen** beinhaltete. Der Leitfaden wurde im Rahmen von zwei Testinterviews mit anderen Wissenschaftlern überprüft und nach einer entsprechenden Überarbeitung vor den Terminen an die Teilnehmer zur Vorbereitung übersandt.

In einem Zeitraum von knapp zwei Monaten wurden insgesamt **neun Interviews**, deren Dauer jeweils 90 bis 120 Minuten betrug, mit gezielt ausgewählten Vertretern verschiedener Unternehmen geführt (siehe Tabelle 8). Von allen involvierten Unternehmen wurden zu diesem Zeitpunkt bereits ML-Anwendungen im Logistikmanagement eingesetzt (sog. Anwender) oder als Produkt vertrieben (sog. Anbieter). Bei den Beteiligten handelte es sich jeweils um Führungskräfte aus Logistik- oder Innovationsbereichen, welche an der Entwicklung und/oder am Betrieb entsprechender Systeme beteiligt waren. Aufgrund der exklusiven Position der Personen in Bezug auf das adressierte Untersuchungsfeld sind die durchgeführten Gespräche auch als **Experteninterviews** zu bezeichnen.⁴⁵⁷

⁴⁵⁷ Vgl. Strübing (2013), S. 95 f.

Unternehmen	ML-Anwendungsfall	Rolle
- Blue Yonder Group, Inc.	- Ermittlung der Ankunftszeiten von Transporten	
- DB Cargo AG	- Ermittlung der Qualität von Produkten im Zielsystem der Kunden	
- DSV Panalpina A/S	- Ermittlung des mittel- bis langfristigen Materialbedarfes	Anwender
- L&G Logistics Group International GmbH	- Ermittlung des zukünftigen Versandvolumens	
- Prewave GmbH	- Ermittlung optimaler Allokationen von Materialien im globalen Produktionsnetzwerk	Anbieter
- Siemens AG	- Ermittlung von Risiken in globalen Lieferketten	
- Schaeffler AG (Automotive Technologies)	- Multi-Echelon-Optimierung von Beständen in Logistiknetzwerken	
- Schaeffler Technologies AG & Co. KG	- Segmentierung von Kundenspezifikationen	
- Thyssenkrupp Material Services GmbH		

Tabelle 8: Teilnehmer der Experteninterviews mit ML-Anwendungsfällen⁴⁵⁸

Mit Zustimmung der Unternehmen wurden die Gespräche aufgezeichnet, wodurch die parallel angefertigten Mitschriften nachträglich ergänzt werden konnten. Zur Ableitung generalisierter Aussagen wurde eine **zusammenfassende qualitative Inhaltsanalyse** durchgeführt, deren systematischer Ablauf sich am Vorgehen von *Mayring (2010)* orientierte. In Hinblick auf die adressierten Forschungsfragen wurden dazu im ersten Schritt mehrere inhaltliche Kategorien festgelegt. Diese sahen neben einer übergeordneten Systematisierung, z. B. in Form von Anforderungen und Potenzialen, auch weitere Untergliederungen vor, z. B. eine Differenzierung nach unterschiedlichen Anforderungen. Im Rahmen einer schrittweisen Prüfung der einzelnen Aussagen erfolgte deren Zuordnung zu diesen Kategorien, wobei stets ein Bezug zum jeweiligen Interview aufrechterhalten wurde. Hierbei mussten iterativ neue Kategorien gebildet und bestehende Kategorien aufgrund einer fehlenden Abdeckung eliminiert werden.

Zur Interpretation der strukturierten Interviewinhalte erfolgte deren Auswertung in Form von **exploratorischen Fallstudien** (Case Studies), welche eine ganzheitliche Erfassung und Analyse von Unternehmenstätigkeiten ermöglichen⁴⁵⁹. Infolge einer Darstellung des jeweiligen Gesamtkontextes kann durch Fallstudien das Verständnis zu den Inhalten und damit verbundenen Zusammenhängen deutlich erhöht werden; gleichzeitig eignet sich diese Methode auch zur Herausstellung erfolgreicher Maßnahmen im Sinne von **Best-Practice-Fällen**, z. B. für die Einführung von Technologien.⁴⁶⁰ Um die Aussagekraft für eine anschließende Theoriebildung zu erhöhen, wurde im vorliegenden Fall eine Mehrfachstudie gewählt, welche eine Darstellung der jeweils fokussierten ML-Anwendungsfälle der einzelnen Unternehmen basierend auf den gebildeten Kategorien umfasste. Hierbei konnte insbesondere die Beantwortung der Forschungsfragen nach den Anwendungsmöglichkeiten („*Was?*“), den resultierenden Auswirkungen („*Warum?*“) und nach geeigneten Umsetzungsmaßnahmen („*Wie?*“) unterstützt werden, wofür exploratorische Fallstudien in besonderem Maße geeignet sind⁴⁶¹.

⁴⁵⁸ Die Unternehmen und Anwendungsfälle sind jeweils alphabetisch sortiert.

⁴⁵⁹ Vgl. Meyer (2003), S. 478

⁴⁶⁰ Vgl. Yin (2009), S. 60 f.

⁴⁶¹ Vgl. Meyer (2003), S. 476

4 Status Quo und Entwicklungen

In Ergänzung zur einleitenden Beschreibung in Kapitel 1.1 wird in diesem Kapitel der gegenwärtige Forschungs- und Praxisstand zum Einsatz von ML-Anwendungen im Logistikmanagement erarbeitet. Zusätzlich werden im Sinne des Gestaltungsanspruches der vorliegenden Arbeit und der damit eingenommenen zukunftsorientierten Betrachtungsperspektive in Bezug auf das Untersuchungsfeld mehrere Entwicklungen ermittelt, welche für die Gestaltung der ML-Anwendungen und des benötigten Umfeldes eine Relevanz aufweisen. Hierdurch soll die zweite sekundäre Forschungsfrage beantwortet werden:

Wie lässt sich der Stand in Forschung und Praxis zum Einsatz von ML-Anwendungen im Logistikmanagement charakterisieren und welche zukünftigen Entwicklungen sind für das Untersuchungsfeld zu erwarten?

Zu Beginn des Kapitels erfolgt eine Systematisierung und Bewertung der für die vorliegende Untersuchung **relevanten Veröffentlichungen**, einschließlich einer Darstellung von deren Einbindung in die Arbeit (Kapitel 4.1). Anschließend wird sowohl die Bedeutung von ML als auch der **Umsetzungsstand** in Bezug auf konkrete Anwendungen und allgemeine Voraussetzungen aus Sicht der logistischen Praxis beschrieben (Kapitel 4.2). Nach dieser branchenweiten Erhebung werden vier ausgewählte **ML-Anwendungsfälle aus der Praxis** zu bereits produktiv eingesetzten Systemen und den damit verbundenen Umsetzungsmaßnahmen analysiert (Kapitel 4.3). Im letzten Schritt erfolgt eine Beschreibung von wichtigen **Forschungstrends zu ML und von weiteren Entwicklungen** des betrachteten Umfeldes mit den Implikationen für das Untersuchungsfeld (Kapitel 4.4).

Die Erkenntnisse dieses Kapitels basieren zum Teil auf einer **explorativen Literaturanalyse**, welche insbesondere der Ermittlung des Forschungsstands und damit verbundener Trends zum Untersuchungsfeld diene. Der Status Quo und die Entwicklungen in der logistischen Praxis wurden dagegen im Rahmen der durchgeführten **Online-Befragung und Experteninterviews** erfasst (siehe Kapitel 3.2). Letzteres bildete zudem die Grundlage für die Fallstudienforschung zur Analyse der exemplarischen Anwendungsfälle.

4.1 Forschungsstand

In diesem Unterkapitel wird der gegenwärtige Forschungsstand und dessen Nutzung für die weiteren Teilziele der vorliegenden Arbeit beschrieben, welche sich auf Fragestellungen zum betrieblichen Einsatz von ML-Anwendungen im Logistikmanagement, insbesondere zu diesbezüglichen Anforderungen und Umsetzungsmaßnahmen sowie zum Anwendungsspektrum und der resultierenden Auswirkungen, beziehen. Wie bereits in Kapitel 1.1 festgestellt, existieren bisher keine wissenschaftlichen Arbeiten, welche die spezifische technische und prozessuale Dimension des vorliegenden Untersuchungsfeldes *gemeinsam* betrachten. Vor diesem Hintergrund wurde bei der durchgeführten Analyse des Forschungsstands eine zusätzliche

isolierte Betrachtung beider Dimensionen und auch deren inhaltliche Erweiterung vorgenommen. Dadurch konnten auch Veröffentlichungen aus anderen Anwendungsbereichen und ohne Bezug zu spezifischen Domänen berücksichtigt werden. Auch wurde somit Literatur zu übergeordneten Technologien einbezogen, d. h. sowohl zu KI und weiteren Datentechnologien als auch zu digitalen Technologien im Allgemeinen. Darüber hinaus erfolgte auch eine Betrachtung von Veröffentlichungen abseits der wissenschaftlichen Forschung, z. B. in Form von Whitepaper und unternehmensbezogenen Studien.

Die nach dieser Vergrößerung des Analysespektrums identifizierten Arbeiten können auf oberster Ebene hinsichtlich ihrer primären Zielsetzung unterschieden werden. Hierbei ist bei der Mehrheit der Veröffentlichungen eine Ausrichtung auf Fragestellungen zum **Entwicklungsprozess** von ML festzustellen – ohne dass jedoch der **betriebliche Einsatz** der Technologie betrachtet wird. Letzterem widmen sich stattdessen stärker anwendungsorientiertere Veröffentlichungen, wobei diese stets eine vom vorliegenden Untersuchungsfeld abweichende technische und/oder prozessuale Fokussierung aufweisen. Darüber hinaus sind Veröffentlichungen separat aufzuführen, welche sich dezidiert auf die Entwicklung oder Systematisierung von **Anwendungsmöglichkeiten zu ML** in der Logistik bzw. dem Logistikmanagement beziehen. Bei einer zusätzlichen Charakterisierung der identifizierten Literatur in Bezug auf die jeweils betrachtete Technologie und den adressierten Anwendungsbereich ergibt sich die in Tabelle 9 dargestellte Systematisierung des relevanten Forschungsstands für die vorliegende Untersuchung, wobei hier zu Darstellungszwecken nur **exemplarische Vertreter** aufgeführt sind. Die daraus hervorgehenden Gruppierungen bilden die Grundlage für die nachfolgenden Ausführungen.

Art der Literatur	Gruppe	Zielsetzung		Technologie		Anwendungsbe- reich		Exemplarische Veröffentlichungen (Stand Dezember 2020)	
		Entwicklungsprozess Anwendungsmöglichkeiten	Betrieblicher Einsatz	Digitale Technologien KI / Datentechnologien	ML	unspezifisch spezifisch, nicht Logistik	Logistik Logistikmanagement		
Wissenschaftliche Monografien, Zeitschriftenartikel oder Beiträge in Sammel- bzw. Konferenzbänden	Technische Grundlagen zu ML	x		(x)	x	x		Alpaydin (2010); Dillmann (1988); Hastie et al. (2009); Han et al. (2011); James et al. (2013); Jordan, Mitchell (2015); Kuhn, Johnson (2013); Marsland (2015); Michalski et al. (1983); Mitchell (1997); Murphy (2012); Russell, Norvig (2016); Sammut, Webb (2017); Weinberger et al. (1994)	
	Gestaltung des Entwicklungsprozesses von ML, inkl. Vorgehensmodelle	x		x	x	x		Akkiraju et al. (2020); Amershi et al. (2019); Chapman et al. (2000); Döbel et al. (2018); Fayyad et al. (1996); Microsoft Corporation (2022); Patel et al. (2008); SAS (2022); Sculley et al. (2015); Wirth, Hipp (2000)	
	Entwicklung von ML- Modellen für logistische Anwendungsfälle		x			x		x	diverse ⁴⁶²
	Forschungsstand zu Anwendungsmöglichkeiten von ML in der Logistik		x			x		x (x)	Agarwal, Jayant (2019); Ni et al. (2019); Giri et al. (2019); Sharma et al. (2020)
	Betrieblicher Einsatz von KI (ohne Logistik- bezug)			x	x (x)	x	x		Buxmann, Schmidt (2019); Gläß (2018); Kreutzer, Sirrenberg (2019); Wittpahl (2019); Mockenhaupt (2021); Wodecki (2019); Wolan (2020)
	Betrieblicher Einsatz von digitalen Techno- logien (mit Logistikbe- zug)		x	x (x)				x (x)	Roy (2017); See (2019); Pflaum et al. (2017); Straube (2019); Vogel-Heuser et al. (2017)
Studien von, Unternehmen, Verbänden o. ä.	Betrieblicher Einsatz von KI und ML mit verschiedenen Schwerpunkten, u. a. Status quo, Trends, Potenziale	(x)	x	x	x	x	x	Acatech (2019); Bitkom, DFKI (2017); BMWI (2019); Böttcher et al. (2017); Bughin et al. (2017); Harvard Business School (2016); Lünendonk (2019); McKinsey (2016); Reder (2020); Seifert et al. (2018); VDMA (2019); Wahlster, Winterhalter (2020)	
	Vorliegende Arbeit	x	x		x			x	

Legende:

x = zutreffend für alle Veröffentlichungen in der Gruppe

(x) = zutreffend für einzelne Veröffentlichungen in der Gruppe oder lediglich implizite Betrachtung

Tabelle 9: Systematisierung des Forschungsstands und Einordnung der Arbeit

⁴⁶² In der Literaturanalyse wurden 112 Veröffentlichungen zu logistischen Entscheidungsprozessen für den Zeitraum 2012 bis 2020 identifiziert (siehe Kapitel 3.1.1).

4.1.1 Entwicklungsprozess

Der Großteil der bestehenden Literatur mit Bezug zu ML befasst sich mit entwicklungsseitigen Fragestellungen. Hierzu sind Veröffentlichungen zu zählen, welche die informationstechnischen, mathematischen und statistischen **Grundlagen von ML** und die einzelnen Lernverfahren beschreiben. Zu diesen oft als Monografien publizierten Veröffentlichungen, welche der vorliegenden Arbeit zur Beantwortung technischer Fragestellungen dienen, zählen u. a. *Alpaydin (2010)*, *Hastie et al. (2009)*, *Jordan, Mitchell (2015)*, *Kuhn, Johnson (2013)*, *Michalski et al. (1983)*, *Mitchell (1997)* und *Russell, Norvig (2016)*. Informationen zur Umsetzung und zum Einsatz von ML im betrieblichen Kontext finden sich hier jedoch nicht. Dementsprechend werden auch nicht die übergeordneten Software- oder Hardwaresysteme betrachtet, in welche die Modelle für die Ausführung zu integrieren sind.

Eine anwendungsorientierte Ausrichtung lässt sich bei mehreren Arbeiten aus dem Bereich der Softwaretechnik (Software Engineering) feststellen, welche sich der Gestaltung des Entwicklungsprozesses von ML widmen. Anders als bei der zuvor dargestellten Gruppe wird den Untersuchungen in diesen Veröffentlichungen ein Einsatz von ML zur Lösung betrieblicher Probleme zugrunde gelegt. Dies betrifft insbesondere Arbeiten mit Informationen zu bedeutenden Vorgehensmodellen für den Entwicklungsprozess, wobei dazu neben ML-spezifischen Ausprägungen auch Modelle für datenbasierte Vorhaben im Allgemeinen zählen, die im ML-Kontext genutzt werden. Als Ausgangspunkt der aus heutiger Sicht relevanten Modelle ist der **KDD-Prozess** (Knowledge Discovery in Databases) anzuführen, welcher von *Fayyad et al. (1996)* begründet wurde und der Extraktion von Wissen aus Daten dient. Beginnend mit der Auswahl relevanter Daten sieht der Prozess deren Aufbereitung, Transformation und explorative Analyse nach Auffälligkeiten, Mustern o. ä. mit einer abschließenden Interpretation der Erkenntnisse vor.⁴⁶³ Die Aktivitäten des KDD beschränken sich damit auf datenanalytische Schritte, welche vor der eigentlichen Anwendungs- bzw. Modellentwicklung erfolgen. Damit entsprechen sie dem heutigen Begriffsverständnis des **Data Mining**.⁴⁶⁴

Diese beim KDD „fehlenden“ Schritte der Entwicklung werden von zwei weiteren Vorgehensmodellen berücksichtigt, welche sich ebenfalls auf Data-Mining-Projekte beziehen, dabei aber Unterschiede in ihren Aktivitäten und im Entstehungshintergrund aufweisen. Hierzu gehört zum einen der **SEMMA-Prozess**, welcher als unternehmenseigene Lösung durch das SAS (2022) entworfen wurde und – im Sinne seines Akronyms – die fünf Schritte Sample, Explore, Modify, Model und Assess umfasst. Bei dem zweiten Modell handelt es sich um den **CRISP-DM** (Cross-Industry Standard Process for Data Mining), welcher mit der Zielsetzung eines branchenübergreifenden Standards von einem durch die Europäische Kommission geförderten Konsortiums Ende der 1990er Jahre entwickelt wurde.⁴⁶⁵ Analog zu SEMMA werden bei diesem Prozess neben den Phasen der Auswahl, Analyse und Aufbereitung der relevanten

⁴⁶³ Vgl. *Fayyad et al. (1996)*, S. 41

⁴⁶⁴ Vgl. *Alpaydin (2010)*, S. 16

⁴⁶⁵ Vgl. *Wirth, Hipp (2000)*, S. 1

Daten auch Aktivitäten zur Modellentwicklung und zu einer anschließenden Bewertung berücksichtigt.⁴⁶⁶ Als Unterschied zwischen beiden Prozessen beinhaltet der CRISP-DM jedoch nicht nur technische Aspekte, sondern auch begleitende Aktivitäten der Softwareentwicklung im Kontext der jeweiligen Projekte. Dies äußert sich zum einen in einer initialen **prozessanalytischen Phase** in Form des sog. Business Understanding, welche u. a. der Erstellung eines Projektplans, der Festlegung der Projektziele und einer Umfeldanalyse dient. Zum anderen existiert auch eine zusätzliche finale Phase, welche die **Bereitstellung** der entwickelten Modelle in die jeweilige produktive Zielumgebung (Deployment) sowie die Dokumentation und Bewertung des durchgeführten Projektes umfasst. Die einzelnen Phasen sind beim CRISP-DM in Form von allgemeingültigen Hauptaktivitäten dokumentiert. Sie führen – analog zum SEMMA- und KDD-Prozess – zu einem iterativ geprägten Vorgehen (siehe Abbildung 35).

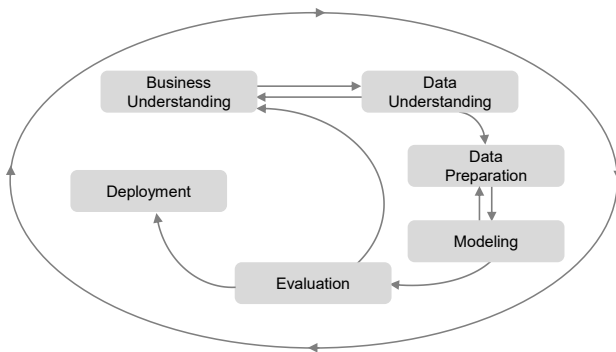


Abbildung 35: Phasen des CRISP-DM⁴⁶⁷

Zusätzlich zu diesen lösungsübergreifenden Vorgehensmodellen existieren auch ML-spezifische Entwicklungsprozesse, wobei sich hierfür bislang jedoch noch kein „Standardmodell“ herausgebildet hat. Bestrebungen in diese Richtung finden gegenwärtig auf internationaler Normungsebene statt, insbesondere in Form der Aktivitäten des Expertengremiums „ISO/IEC JTC 1/SC 42“, welche zu dem im Jahre 2022 veröffentlichten Rahmenwerk für Entwicklungsprozesse von ML in Form der Norm ISO/IEC 23053:2022 geführt haben⁴⁶⁸. Bei weiteren Prozessen in diesem Kontext handelt es sich dagegen um autoren- bzw. unternehmensspezifische Modelle. Hierzu zählt der **TDSP** (Team Data Science Process), welcher von der *Microsoft Corporation* (2022) begründet wurde. Die Hauptphasen dieses Prozesses entsprechen dem CRISP-DM; sie enthalten aber ML-spezifische Aktivitäten, welche allerdings nur oberflächlich beschrieben sind. Dies begründet sich in der Zielstellung des TDSP, welcher primär eine methodische Unterstützung des Entwicklungsprozesses vorsieht, insbesondere in

⁴⁶⁶ Vgl. hierzu und zu diesem Abschnitt Chapman et al. (2000), S. 13 ff.

⁴⁶⁷ Eigene Darstellung in Anlehnung an Chapman et al. (2000), S. 10

⁴⁶⁸ Vgl. ISO (2022)

Bezug auf die Projektplanung und -organisation. Dazu werden entlang des Prozesses verschiedene Werkzeuge bereitgestellt, z. B. Vorlagen für MS Excel und MS Project, aber auch in Form weiterer Microsoft-Produkte.

Als weiterer Vertreter ist der **ML-Workflow** von *Amershi et al. (2019)* zu nennen, welcher auf Grundlage verschiedener Projekte – ebenfalls im Umfeld von Microsoft – entstanden ist und dabei erneut dezidiert die Modellentwicklung adressiert (siehe Abbildung 36). Somit finden sich auch keine projektbegleitenden Aktivitäten zur Entwicklung. Als initiale Phase sieht dieser Prozess ebenfalls eine analytische Auseinandersetzung mit der zugrundeliegenden Problemstellung vor, welche in diesem Fall jedoch einer **Bewertung der Realisierbarkeit mittels ML** und einer Vorauswahl geeigneter Lernverfahren dient.⁴⁶⁹ Während die datenanalytischen Phasen weitestgehend mit dem CRISP-DM korrespondieren, existiert mit dem Feature Engineering (Merkmalsbildung bzw. -konstruktion) eine zusätzliche Phase, welche als Schnittstelle zwischen den datenanalytischen und entwicklungsseitigen Tätigkeiten eine Identifikation, Bewertung und Auswahl potenzieller Features beinhaltet. Zudem ist die eigentliche Modellentwicklung in zwei Phasen unterteilt, wobei das Model Training die Implementierung der jeweiligen Lernverfahren mit einer geeigneten Parametrisierung anhand von Trainingsfällen umfasst (siehe Kapitel 2.4.3.2) und die Model Evaluation der finalen Testung der resultierenden Modelle anhand festgelegter Metriken dient. Die abschließenden Phasen des Model Deployment und Model Monitoring dienen der Bereitstellung der Modelle in die Zielumgebung und deren kontinuierlicher Überwachung. Neben einer sehr prägnanten Darstellung der einzelnen Phasen, welche ebenfalls iterativ zu durchlaufen sind, werden in der zugrundeliegenden Veröffentlichung verschiedene Best-Practice-Maßnahmen aufgezeigt, wozu u. a. – in Anlehnung an klassische ETL-Pipelines (Extract, Transform, Load) für die Datenintegration – die Umsetzung eines automatisierten Prozesses für die beschriebenen Entwicklungsaktivitäten zur Anpassung der Modelle im produktiven Betrieb zählt (sog. ML-Pipeline).




Abbildung 36: Entwicklungsprozess von ML-Modellen⁴⁷⁰

Bei einer Gesamtbetrachtung der im erweiterten Kontext von ML bestehenden Vorgehensmodelle ist festzustellen, dass deren **Fokus stets auf der Entwicklung** – im Speziellen auf der Modellentwicklung – liegt, sodass Aktivitäten zur Umsetzung des jeweiligen Gesamtsystems in Form einer Anwendung sowie deren Integration in die betriebliche Zielumgebung nur oberflächlich dargestellt sind. Für technische Herausforderungen des produktiven Betriebs von ML-

⁴⁶⁹ Vgl. hierzu und zu diesem Abschnitt Amershi et al. (2019), S. 292 f.

⁴⁷⁰ Eigene Darstellung in Anlehnung an Amershi et al. (2019), S. 292

Anwendungen, z. B. die Anbindung aller relevanten Datenquellen und die Realisierung eines Re-Trainings, sind demnach nur punktuell Maßnahmen berücksichtigt. Informationen zu Aktivitäten abseits der Entwicklung werden nur vom CRISP-DM und TDSP berücksichtigt, wobei sich diese jedoch nur auf die jeweiligen Projekte beziehen und darüber hinaus nur Teilaspekte abdecken. Demnach wird u. a. in beiden Fällen von einer Eignung der genutzten Technologie für den jeweiligen Anwendungsfall ausgegangen. Eine Prüfung der Realisierung mittels ML, wie sie der Prozess von *Amershi et al. (2019)* – jedoch ohne Vorgabe entsprechender Maßnahmen – beinhaltet, wird nicht berücksichtigt. Darüberhinausgehende Aktivitäten zur Gestaltung des Umfelds in den Unternehmen in Form projekt- bzw. anwendungsübergreifender Voraussetzungen, z. B. auf infrastruktureller oder organisatorischer Ebene, finden sich bei keinem der bisherigen Vorgehensmodelle.

Trotz dieser eingeschränkten Abdeckung von notwendigen Aktivitäten zum betrieblichen Einsatz von ML bilden die bestehenden Modelle eine wichtige **Grundlage für den Erkenntnisprozess** in der vorliegenden Arbeit, insbesondere bei der Entwicklung eines Vorgehens für den Gestaltungsansatz. Als weitere relevante Literatur für die Arbeit mit einer ebenfalls entwicklungsseitigen Ausrichtung wurden zudem mehrere Veröffentlichungen identifiziert, welche sich spezifischen Themenstellungen des Entwicklungsprozesses von ML widmen. Hierzu gehören die Veröffentlichungen von *Patel et al. (2008)* zu allgemeinen Herausforderungen bei der Entwicklung, von *Sculley et al. (2015)* zur Vermeidung von technischen Schulden, von *Breck et al. (2017)* zu Verfahren für die Modelltestung und -überwachung, von *Mitchell et al. (2019)* zur Dokumentation von entwickelten Modellen sowie von *Akkiraju et al. (2020)* zur Reifegradbewertung der Prozesse. Auch ist die Arbeit von *Döbel et al. (2018)* zu nennen, aus der relevante Forschungstrends extrahiert werden konnten.

4.1.2 Anwendungsmöglichkeiten

Als weitere relevante Gruppe von Veröffentlichungen konnten Arbeiten identifiziert werden, welche sich auf den Einsatz von ML zur **Lösung individueller Probleme** in der Logistik beziehen, wobei dies auch vielfach logistische Entscheidungsprozesse umfasst. Auch bei diesen Veröffentlichungen, welche zumeist als Artikel in wissenschaftlichen Zeitschriften und Konferenzbänden publiziert sind, steht die Beantwortung entwicklungsseitiger Fragestellungen im Fokus. Durch Testung verschiedener Modellkonfigurationen und teilweise auch mehrerer Lernverfahren wird für den jeweiligen Anwendungsfall das geeignetste Entwicklungskonzept ermittelt. Dazu erfolgt eine Beschreibung des häufig sehr experimentell geprägten Entwicklungsprozesses, wobei sich dieser in den meisten Fällen auf die Umsetzung der ML-Modelle beschränkt. Die Entwicklung des jeweiligen Gesamtsystems in Form einer Anwendung sowie deren Integration in die betriebliche Zielumgebung werden dagegen erneut nicht dargestellt. Vielmehr streben die Autoren einen technischen Machbarkeitsbeweis in Form eines **Proof of Concept (PoC)** an, der lediglich die Realisierung eines prototypischen Systems vorsieht. Vor

diesem Hintergrund finden sich in diesen Arbeiten auch keine Informationen zu weiteren Anforderungen oder Maßnahmen des betrieblichen Einsatzes von ML-Anwendungen. Dennoch konnten viele dieser Veröffentlichungen für die Ermittlung des Anwendungsspektrums in der vorliegenden Arbeit genutzt werden (siehe Kapitel 3.1.1).

In weiteren Veröffentlichungen werden diese bestehenden Artikel zu logistischen Anwendungsfällen genutzt, um durch deren Zusammenführung und Analyse übergreifende Erkenntnisse zum Forschungsstand der Anwendungsmöglichkeiten von ML zu gewinnen. Insgesamt konnten **16 Übersichtsarbeiten** (Literature Reviews) ermittelt werden, welche im weitesten Sinne Schnittmengen mit der prozessualen und/oder technischen Dimension des in der vorliegenden Arbeit betrachteten Untersuchungsfeldes aufweisen – wobei jedoch in nur wenigen Arbeiten eine vollständige Abdeckung vorzufinden ist.⁴⁷¹ Demnach erfolgt in mehreren Fällen eine Beschränkung auf ausgewählte logistische Teilsysteme, wie die Produktionslogistik, z. B. *Krauß et al. (2019)* und *Wang et al. (2018a)*, auf bestimmte Einsatzbereiche, wie das Supply Chain Risk Management (SCRM) oder das Supply Chain Performance Management (SCPM), z. B. *Baryannis et al. (2019b)* und *Lima-Junior, Carpinetti (2017)*, oder auf spezifische Logistikketten, wie für Kleidung und Landwirtschaft, z. B. *Giri et al. (2019)* und *Sharma et al. (2020)*. Eine explizite Betrachtung von Entscheidungsprozessen in der Logistik erfolgt nur von *Peidro et al. (2009)*, jedoch in diesem Fall für einen anderen technischen Betrachtungsbereich in Form allgemein quantitativer Methoden. Die Abweichungen bei der technischen Dimension ergeben sich u. a. durch eine andere definitorische Abgrenzung von ML. Demnach fokussieren mehrere Veröffentlichungen bestimmte Lerntypen oder -verfahren, wie Deep Learning oder KNN, z. B. *Wang et al. (2018a)* und *Bousqaoui et al. (2017)*. Oftmals finden sich auch keine Anwendungen zum RL, was auch in Verbindung mit dem Erscheinungszeitpunkt und dem diesbezüglichen Forschungsstand steht, z. B. *Ngai et al. (2014)*. Andere Arbeiten wählen dagegen einen größeren technischen Betrachtungsbereich, wie KI im Allgemeinen, z. B. *Min (2010)*, Supply Chain Event Processing (SCEP), z. B. *Konovalenko, Ludwig (2019)*, Data Analytics, z. B. *Herden, Bunzel (2018)*, sowie die bereits angesprochenen quantitativen Methoden, z. B. *Peidro et al. (2009)* und *Lima-Junior, Carpinetti (2017)*. In all diesen Fällen werden nur vereinzelt ML-Anwendungen berücksichtigt und daher auch deren Spezifika nicht gesondert herausgestellt.

In Bezug auf das technische Spektrum bei der Identifikation von Anwendungen verweisen mehrere Autoren auch auf die Bedeutung einer möglichst umfassenden Betrachtung von ML. *Wang et al. (2018a)* und *Bousqaoui et al. (2017)* beziehen diese Aussage auf den vergleichsweise „modernen“ Lerntyp des Deep Learning, welcher bisher nach ihren Erkenntnissen wenig Berücksichtigung findet. *Ngai et al. (2014)* und *Min (2010)* konstatieren selbiges für Verfahren des Evolutionary Learning, welche bisher ebenfalls nur in wenigen Reviews betrachtet werden. *Ni et al. (2019)* und *Baryannis et al. (2019b)* stellen grundsätzlich fest, dass viele mitunter „moderne“ Lernverfahren in den von ihnen betrachteten Anwendungen der Logistik noch nicht

⁴⁷¹ Eine Systematisierung der Literature Reviews findet sich in Tabelle 33 im Anhang.

vorkommen. Vor diesem Hintergrund weisen *Hellingrath, Lechtenberg (2019)* auf die Notwendigkeit einer **kontinuierlicher Überprüfung des Anwendungsspektrums** für das jeweilige Untersuchungsfeld hin.

Hinsichtlich der methodischen Vorgehensweise ist festzustellen, dass drei Viertel der untersuchten Reviews eine systematische Ermittlung der Veröffentlichungen mittels Suchstrings über wissenschaftliche Datenbanken vornehmen. Bis auf die Arbeiten von *Bousqaoui et al. (2017)*, *Giri et al. (2019)* und *Ngai et al. (2014)*, die sich auf eine bibliografische Beschreibung der Anwendungen beschränken, werden in allen Arbeiten die ermittelten Veröffentlichungen bzw. die darin enthaltenen Anwendungen nach prozessualen und/oder technischen Merkmalen charakterisiert. Der Großteil der Arbeiten adressiert dabei jedoch eine rein **deskriptive Erfassung des Forschungsstands**, ohne dass Ableitungen zum potenziell realisierbaren oder geeigneten Anwendungsspektrum gezogen werden. Zudem handelt es sich in den in meisten Fällen um eine univariate Analyse, bei der die Ausprägungen jedes Merkmals entweder qualitativ oder quantitativ mittels Häufigkeitsverteilungen ausgewertet werden.

Eine in mehreren Arbeiten vorgenommene Charakterisierung erfolgt für den Anwendungsbeereich, indem die einzelnen Anwendungen in bestehende Prozessmodelle manuell eingeordnet werden. Hierfür nutzen *Hellingrath, Lechtenberg (2019)* die SCP-Matrix, *Wenzel et al. (2019)* das Supply-Chain-Task-Modell und *Konovalenko, Ludwig (2019)* das Supply-Chain-Operation-Reference-Modell (SCOR). Bei einem Vergleich von ähnlichen Anwendungsfällen in diesen Reviews zeigt sich jedoch eine fehlende Eindeutigkeit bei dieser Zuordnung. Vor diesem Hintergrund nutzen weitere Autoren, wie *Min (2010)* und *Krauß et al. (2019)*, eine individuelle Systematisierungslogik, welche dem prozessübergreifenden Charakter vieler Anwendungen und den oft vielfältigen Nutzungsmöglichkeiten, z. B. im Falle einer Nachfrageprognose (sog. Demand Forecasting), stärker gerecht wird. Im Rahmen dieser prozessualen Charakterisierung stellen einzelne Arbeiten auch einen Zusammenhang zur technischen Gestaltung der Anwendungen her, was jedoch lediglich anhand eines weiteren Merkmals in Form häufig verwendeter Lernverfahren erfolgt. Auch konstatieren einige Autoren, wie *Wenzel et al. (2019)* und *Sharma et al. (2020)*, dass oftmals mehrere Verfahren für eine Problemstellung eingesetzt werden, weshalb diesbezügliche Aussagen nur bedingt generalisierbar sind.

Eine darüberhinausgehende Betrachtung von Zusammenhängen zwischen verschiedenen technischen und prozessualen Eigenschaften erfolgt in der Arbeit von *Lima-Junior, Carpinetti (2017)*, in der die betrachteten Anwendungen – in dem Falle zur Leistungsbewertung von Lieferketten auf Basis von quantitativen Methoden – anhand von elf Merkmalen charakterisiert werden. Die Ergebnisse gehen jedoch auch in dieser Arbeit nicht über eine deskriptive Darstellung hinaus, welche sich in einer Auflistung der Anwendungen mit den jeweiligen Merkmalsausprägungen äußert. Einzig in der Arbeit von *Herden, Bunzel (2018)* wird die Charakterisierung bestehender Anwendungen gezielt für eine Hypothesenbildung zum gesamten Anwendungsspektrum genutzt. Anhand der Ausprägung von 34 Merkmalen setzen die Autoren dazu eine rechnergestützte Gruppierung der Anwendungen auf Basis der Ward-Methode um.

Allerdings handelt es sich auch bei dieser Veröffentlichung um einen von der vorliegenden Arbeit abweichenden Untersuchungsbereich in Form von Data-Analytics-Anwendungen, welche darüber hinaus eine geringe Abdeckung von Fällen aus der Produktionslogistik aufweisen.

Entsprechend der aufgeführten Einschränkungen der bestehenden Übersichtsarbeiten konnten diese nicht für eine abschließende Ableitung des Anwendungsspektrums von ML im Logistikmanagement genutzt werden. Mit den Arbeiten von *Agarwal, Jayant (2019)*, *Ni et al. (2019)*, *Giri et al. (2019)* und *Sharma et al. (2020)* wurden allerdings vier Veröffentlichungen zur Extraktion von relevanten Anwendungsfällen für die vorliegende Arbeit ermittelt (siehe Kapitel 3.1.1). Auch wurden darüber hinaus Erkenntnisse zur Abgrenzung des Untersuchungsfelds und zum methodischen Vorgehen gewonnen. Demnach war u. a. festzustellen, dass die angestrebte Typenbildung eine geeignete Methodik zur Systematisierung des Anwendungsspektrums und zur Ermittlung von Zusammenhängen zwischen prozessualen und technischen Eigenschaften der Anwendungen darstellt. Zu den weiteren Forschungsfragen hinsichtlich des betrieblichen Einsatzes von ML konnten – entsprechend des Informationsgehaltes der den Reviews zugrundeliegenden Artikeln – dagegen keine Erkenntnisse erzielt werden.

4.1.3 Betrieblicher Einsatz

Für die bisher nicht abgedeckten Informationen zum betrieblichen Einsatz lassen sich zwei Gruppen von wissenschaftlichen Veröffentlichungen identifizieren, welche teilweise in Bezug auf die vorliegende Arbeit ähnliche Fragestellungen adressieren – jedoch stets in einem abweichenden technischen und/oder prozessualen Kontext.

Zum einen handelt es sich um Veröffentlichungen zum **betrieblichen Einsatz von KI**, in denen ML entweder im- oder explizit eine Berücksichtigung findet. Ein Bezug zum Logistikmanagement bzw. zur Logistik im Allgemeinen wird in diesen Arbeiten jedoch nicht hergestellt. Hierzu gehören u. a. die Veröffentlichungen von *Buxmann, Schmidt (2019)* und von *Kreutzer, Sirrenberg (2019)*, welche ausgehend von einem Gesamtüberblick zu KI die Umsetzung anhand von individuellen Anwendungsfällen aus der Praxis beschreiben. Auch existieren Arbeiten zum Einsatz von KI für spezifische Anwendungsbereiche, z. B. *Gläß (2018)* für den Handel. Andere Veröffentlichungen fokussieren bestimmte betriebswirtschaftliche Themenbereiche im Kontext von KI, wie *Wodecki (2019)* zur Erzielung von Wertschöpfungsvorteilen oder *Wittpahl (2019)* und *Wolan (2020)* zu möglichen Auswirkungen für Unternehmen. Hervorzuheben ist die Arbeit von *Mockenhaupt (2021)*, in der neben einer technischen und anwendungsbereichsbezogenen Darstellung des Einsatzes von KI bzw. ML Überlegungen zu deren Einsatz in Entscheidungsprozessen vorgenommen werden. Eine Beschreibung geeigneter Maßnahmen für die Begegnung damit verbundener Herausforderungen erfolgt jedoch nicht.

Zum anderen existieren Veröffentlichungen, welche sich einem **betrieblichen Einsatz von digitalen Technologien** im Allgemeinen widmen – wobei dies explizit für die Logistik bzw. teilweise auch für das Logistikmanagement erfolgt. Anders als bei der zuvor genannten

Gruppe findet hier jedoch keine spezifische Betrachtung von ML oder KI statt, sodass besondere Eigenschaften und Anforderungen dieser Technologien unberücksichtigt bleiben. Als Vertreter sind u. a. *Roy (2017)* und *Vogel-Heuser et al. (2017)* zu nennen, welche sich mit dem Einsatz von digitalen Technologien für die Realisierung des Zukunftskonzepts der Industrie 4.0 beschäftigen und hierzu u. a. geeignete Umsetzungsmaßnahmen ermitteln. Selbiges gilt für die Arbeit von *See (2019)*, in der dieser Technologieverbund im Kontext der digitalen Transformation der Logistik betrachtet und dabei auf die in den bisherigen Untersuchungen **unterrepräsentierte Betrachtung der organisatorischen bzw. sozialen Dimension** verwiesen wird. Die Veröffentlichungen von *Straube (2019)* und *Pflaum et al. (2017)* stellen wissenschaftliche Studien dar, welche sich insbesondere auf die möglichen Auswirkungen digitaler Technologien für die Logistik beziehen, wobei letztgenannte Arbeit eine zusätzliche Beschränkung auf den Bereich der Transportlogistik vornimmt.

Entsprechend der abweichenden technischen und/oder prozessualen Betrachtungsbereiche der genannten Veröffentlichungen konnten damit verbundene Ergebnisse nicht für die vorliegende Untersuchung übertragen werden. Dennoch fanden die Arbeiten an mehreren Stellen des Forschungsprozesses eine Berücksichtigung, u. a. zur Gestaltung der Methodik sowie zur Systematisierung und zum **Ableich der erzielten Erkenntnisse**, um etwaige Spezifika des vorliegenden Untersuchungsfeldes festzustellen. Eine analoge Einbindung haben Arbeiten erfahren, welche tendenziell nicht der wissenschaftlichen Forschung entstammen oder keinen nachprüfbaren Erkenntnisprozess aufweisen. Diese widmen sich zwar bestimmten Themenstellungen des betrieblichen Einsatzes von ML bzw. KI; entsprechend ihres Entstehungshintergrundes sind sie allerdings von den bisherigen Veröffentlichungen zu separieren. Hierbei handelt es sich zumeist um im Studienformat oder als Whitepaper publizierte Arbeiten von Unternehmen, Verbänden oder politischen Institutionen, welche dem populärwissenschaftlichen Bereich oder der „grauen Literatur“ zuzuordnen sind. Die Betrachtungen erfolgen dabei entweder branchenübergreifend oder für spezifische Marktsegmente. Eine auf das Logistikmanagement oder die Logistik spezialisierte Veröffentlichung findet sich dabei nicht.

Mehrere der relevanten Veröffentlichungen in dieser Gruppe stellen die Ergebnisse empirischer Befragungen vor, welche in einem bestimmten regionalen Kontext zu betrieblichen Fragestellungen von ML oder KI durchgeführt wurden, v. a. in Bezug auf den Umsetzungsstand und die realisierbaren Potenziale. Hierzu gehören die ML-spezifischen Studien von *Böttcher et al. (2017)* und *Reder (2020)*, welche für die DACH-Region erstellt wurden und jeweils zu einem kleinen Teil (ca. 10 %) Logistikvertreter einbezogen haben. In *McKinsey (2016)* und der ebenfalls auf McKinsey zurückgehenden Studie von *Bughin et al. (2017)* wurden diese Informationen im Rahmen einer globalen Untersuchung ausgewiesen. Teilweise erfolgte dabei ein Vergleich der Logistik mit anderen Branchen, woraus sich für die Logistik ein hohes Potenzial von KI bzw. ML, aber auch ein vergleichsweise geringer Umsetzungsstand erkennen lässt. In der auf Basis von Einzelinterviews durchgeführten Studie von *Lünendonk (2019)* wurden zusätzliche Herausforderungen für den Einsatz von KI ermittelt und diesbezügliche Maßnahmen

ausgewiesen. Empfehlungen für die Umsetzung von ML – allerdings in diesem Fall abseits einer empirischen Untersuchung – finden sich auch in *Harvard Business School (2016)*. Weitere Veröffentlichungen beziehen sich auf bestimmte Anwendungsbereiche, die zumeist sehr breit gefasst sind. Hierzu zählt die Arbeit von *Acatech (2019)* zur Beschreibung von Einsatzmöglichkeiten von ML im Mobilitätsbereich sowie die KI-Studien von *Seifert et al. (2018)* und dem *BMW (2019)* in Bezug auf die Industrie, welche u. a. individuelle Autonomiestufen und Handlungsempfehlungen ausweisen. Auch ist in diesem Kontext die spezialisierte Studie vom *VDMA (2019)* zu nennen, in der die Nutzung von Reinforcement Learning in der Produktion beschrieben wird. Die Untersuchung eines bestimmten Schwerpunktthemas findet sich auch in anderen Arbeiten, wobei die Studie von *Bitkom, DFKI (2017)* hervorzuheben ist, welche sich der Nutzung von KI zur Entscheidungsunterstützung widmet und dabei ähnliche Fragestellungen wie die vorliegende Arbeit adressiert – allerdings mit einem Fokus auf ethische und rechtliche Anforderungen sowie ohne Bezug zur Logistik. In der ebenfalls spezialisierten Untersuchung von *Wahlster, Winterhalter (2020)* wird der Normungsstand zu KI und ein damit verbundener Handlungsbedarf erarbeitet.

4.2 Praxisstand

An die Analyse des Forschungsstands schließt sich die Bewertung des Umsetzungsstands und der Bedeutung von ML aus Praxissicht an. Im Rahmen der empirischen Untersuchung wurde dazu festgestellt, dass ML für die Mehrheit der Unternehmen (59 %) eine **Schlüsseltechnologie** in der Logistik darstellt, aus der ein hohes Anwendungsspektrum erwächst (siehe Abbildung 37). Weitere 34 % bestätigen diese Sichtweise in Bezug auf bestimmte logistische Bereiche. Von einer starken Beschränkung des Einsatzes der Technologie in Bezug auf einzelne Anwendungsfälle gehen dagegen nur 7 % der Unternehmen aus. Bei einer differenzierten Betrachtung ist festzustellen, dass ML für erfolgreiche Unternehmen eine vergleichsweise hohe Bedeutung in der Logistik einnimmt. Demnach nehmen 75 % der Unternehmen ML als Schlüsseltechnologie wahr, wohingegen diese Sichtweise nur von 46 % der Unternehmen des Branchendurchschnitts vertreten wird. Bei einem Vergleich der Branchenzugehörigkeit zeigt sich diese hohe Bedeutung im Falle von 65 % der Industrieunternehmen. Bei den Logistikdienstleistern sind es dagegen nur 44 %.




Abbildung 37: Anwendungsspektrum von ML in der Logistik⁴⁷²

Neben dem breiten Anwendungsspektrum assoziiert der Großteil der Unternehmen (84 %) mit dem Einsatz von ML auch ein hohes Veränderungspotenzial für die Logistik (siehe Abbildung 38). Dies umfasst sowohl prozessuale und organisatorische Auswirkungen innerhalb der einzelnen Unternehmen als auch Veränderungen der gesamten Wertschöpfungskette und Wettbewerbsstruktur. In diesem Zusammenhang bezeichnen mehrere Unternehmen ML auch als **disruptive Innovation** und als einen wesentlichen Treiber der digitalen Transformation.




Abbildung 38: Veränderungspotenzial von ML für die Logistik⁴⁷³

Die Vielzahl an Anwendungsmöglichkeiten und die damit verbundenen Nutzenpotenziale münden bei 77 % der Befragten in der Feststellung, dass die Wettbewerbsfähigkeit des eigenen Unternehmens im Falle eines nicht erfolgten Einsatzes von ML in der Logistik langfristig sinken wird (siehe Abbildung 39). Nur 10 % vertreten hierzu eine gegenteilige Meinung. Diese **hohe strategische Bedeutung** von ML geht v. a. auf die Lernfähigkeit der darauf basierenden Anwendungen zurück, die neben der Erhöhung der Transparenz auch eine semi- bis vollautonome Ausführung von Logistikprozessen ermöglicht. Demnach sehen 73 % der Unternehmen ML als Grundlage für die Realisierung autonomer Systeme.




Abbildung 39: Strategische Bedeutung von ML in der Logistik⁴⁷⁴

⁴⁷² Eigene Darstellung

⁴⁷³ Eigene Darstellung

⁴⁷⁴ Eigene Darstellung

Ausgehend von dieser übergreifenden Betrachtung wurde zusätzlich die Bedeutung von ML in Hinblick auf die drei logistischen Aufgabenarten gemäß der Unterteilung in Kapitel 2.2.2 erhoben. Hieraus ist übergreifend eine hohe Bedeutung für alle Ausprägungen abzuleiten (siehe Abbildung 40), wobei auch marginale Unterschiede festzustellen sind. Diese äußern sich in einer etwas geringeren Bedeutung von ML für ausführende Aufgaben (4,0) gegenüber Planungs-, Steuerungs- und Kontrollaktivitäten. Das höchste Bedeutungs-niveau im Rahmen von Entscheidungsprozessen nehmen dabei **planerische Aufgaben** ein (4,3).




Abbildung 40: Bedeutung von ML für logistische Aufgabenarten⁴⁷⁵

Zusätzlich zur Bedeutung wurde auch der Umsetzungsstand von ML in der logistischen Praxis ermittelt. Dazu erfolgte eine Einordnung der Unternehmen in vorgegebene Phasen, welche in Abbildung 41 dargestellt sind und sich am Adoptionsprozess aus Kapitel 2.1.3.1 orientieren, wobei für die vorliegende Untersuchung eine stärkere Untergliederung vorgenommen wurde. Diese Systematik bildet auch die Grundlage für die in Kapitel 3.2.3 beschriebene Unterscheidung in Adopter und Non-Adopter von ML.

Non-Adopter				Adopter		
Wahrnehmung		Untersuchung		Entwicklung und Erprobung		
Keine Relevanz	Interesse	Analyse	Planung	Prototyp	Punktue-ller Einsatz	Flächendeckender Einsatz
Es werden bislang keine Aktivitäten un-ternommen. Das Thema ist für das Unter-nehmen nicht relevant.	Es werden bislang keine Aktivitäten un-ternommen, aber das Thema ist für das Unternehmen interessant.	Es wird nach Möglichkeiten zur Umsetzung gesucht.	Die Umsetzung konkreter An-wendungen wird verhandelt bzw. konzeptioniert.	Es werden erste Anwendungen im Pilotstadium getestet.	Es sind erste produktive Anwendungen in den Prozessen integriert.	Es sind in weiten Teilen produktive Anwendungen in den Prozessen umgesetzt.

Abbildung 41: Phasen des Umsetzungsstands von ML⁴⁷⁶

Trotz deren hoher strategischer Bedeutung wurde festgestellt, dass knapp 75 % der befragten Unternehmen bislang über **keine ML-Anwendungen in der Logistik** verfügen – weder als produktive noch als prototypische Systeme (siehe Abbildung 42). Bei nur einem kleinen Teil dieser Non-Adopter (insgesamt 5 %) geht die fehlende Umsetzung auf eine geringe Relevanz von ML für das jeweilige Unternehmen zurück; alle anderen Vertreter bekunden mindestens ein Interesse an der Umsetzung. Die Mehrheit der Non-Adopter (insgesamt 41 %) sucht dabei

⁴⁷⁵ Eigene Darstellung

⁴⁷⁶ Eigene Darstellung

bereits aktiv nach geeigneten Anwendungsmöglichkeiten im Unternehmen. Weitere 10 % planen darüber hinaus die Umsetzung konkreter Anwendungen. Von den 25 % der Unternehmen, die bereits über umgesetzte Anwendungen in der Logistik verfügen, entfällt der Großteil auf prototypische Systeme (insgesamt 15 %). Produktive Anwendungen werden dagegen bisher nur von ca. 10 % der Unternehmen genutzt, wobei sich dies ausschließlich auf einen punktuellen Einsatz bezieht. Eine flächendeckende Nutzung weist bislang keines der Unternehmen auf. Eine Differenzierung des Umsetzungsstands nach spezifischen Unternehmensmerkmalen zeigt zudem, dass 32 % der erfolgreichen Unternehmen der Gruppe der Adopter zuzuordnen sind. Bei den Unternehmen des Branchendurchschnitts sind es dagegen nur 17 %. Neben den zuvor ermittelten Unterschieden in Bezug auf die Bedeutung von ML kann dies auch auf die finanziellen bzw. personellen Voraussetzungen der Unternehmen zurückgeführt werden, welche gerade bei kleineren, wirtschaftlich schwächeren Unternehmen die Möglichkeiten zur Forschung und Entwicklung von technischen Innovationen einschränken.

Für den Umsetzungsstand ist aber auch festzustellen, dass dessen geringe Ausprägung kein unternehmensweites Phänomen darstellt. Vielmehr weisen andere Funktionsbereiche bereits eine stärkere Ausbreitung von ML-Anwendungen im Vergleich zur Logistik auf, was sich in einer **Rechtsverschiebung der Diffusionskurve** äußert. Statt der zuvor genannten 10 % in Bezug auf die Logistik verfügen bereits 26 % der Unternehmen über produktive Anwendungen in anderen Bereichen. Ein flächendeckender Einsatz ist allerdings auch hier noch nicht zu verzeichnen.




Abbildung 42: Umsetzungsstand von ML in Unternehmensbereichen⁴⁷⁷

Die Betrachtung der einzelnen logistischen Aufgabenarten zeigt auch im Falle des Umsetzungsstands mehrere Unterschiede, wobei diese im Vergleich zur Bedeutung deutlich stärker ausgeprägt sind (siehe Abbildung 43). Die **meisten prototypischen und produktiven ML-Anwendungen existieren für ausführende Aktivitäten**, wozu u. a. autonome Fahrzeuge

⁴⁷⁷ Eigene Darstellung. Die Prozentangaben beziehen sich auf die Logistik.

(FTS) und Roboter, aber auch Chatbots zählen. Diese finden sich bereits bei 41 % der Unternehmen. Ein etwas geringerer Umsetzungsstand lässt sich in Bezug auf Anwendungen für Kontrollaufgaben feststellen, welche bereits bei 33 % der Unternehmen vorhanden sind. Zu den vorherrschenden ML-Anwendungen in diesem Kontext zählen v. a. Systeme zur Sprach- und Bilderkennung, die den KI-Teilbereichen NLP und Computer Vision zuzuordnen sind. Nur 21 % der Unternehmen verfügen dagegen über Anwendungen für logistische Planungs- und Steuerungsaktivitäten, was im Vergleich zu den anderen Aufgabenarten den geringsten Umsetzungsstand ergibt. Zu diesen Aufgaben ist jedoch auch festzustellen, dass bereits vergleichsweise viele Unternehmen (28 %) eine Umsetzung konkreter Anwendungen vorsehen, was die damit assoziierte Bedeutung verdeutlicht.

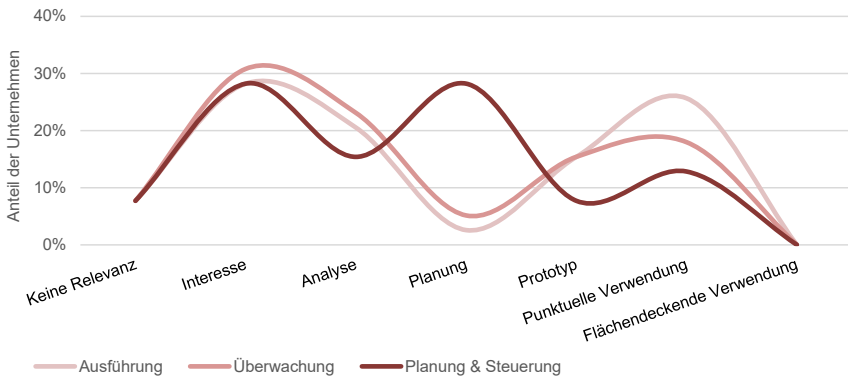


Abbildung 43: Umsetzungsstand von ML für logistische Aufgabenarten⁴⁷⁸

Bei einem Vergleich der Befragungsergebnisse zur Bedeutung und zum Umsetzungsstand von ML in der Logistik ist eine **hohe Diskrepanz** zu erkennen, die im Falle von Entscheidungsprozessen besonderes stark ausgeprägt ist. Die bisherigen Anwendungen werden demnach den hohen strategischen Potenzialen der Technologie nicht gerecht. Um Aussagen über die Möglichkeiten der Unternehmen zur gezielten Begegnung des damit verbundenen Handlungsbedarfes tätigen zu können, wurde zusätzlich deren Wissensstand in Bezug auf einen Einsatz von ML in der Logistik ermittelt, da dieser gemäß den Erkenntnissen aus Kapitel 2.1.3.1 die Basis für einen Diffusions- bzw. Adoptionsprozess darstellt. Dies betrifft zum einen Wissen zu Anwendungsmöglichkeiten sowie zu damit erzielbaren Nutzenpotenzialen für die Unternehmen. Zum anderen sind Kenntnisse zu benötigten Voraussetzungen für den Technologieeinsatz und zu damit verbundenen Umsetzungsmaßnahmen erforderlich, um die Realisierbarkeit und den Aufwand im jeweiligen Unternehmen bewerten zu können. Für all diese notwendigen Informationen wurde ein **ausgeprägtes Wissensdefizit** in der Logistikbranche festgestellt (siehe Abbildung 44). Demnach verfügen nur 44 % der Unternehmen über Kenntnisse zu An-

⁴⁷⁸ Eigene Darstellung

wendungsmöglichkeiten und Potenzialen. Im Falle der benötigten Voraussetzungen und Maßnahmen sind es lediglich 31 %. Zusammenfassend ist daher festzuhalten, dass die zentralen Fragen für einen erfolgreichen Technologieeinsatz in Form des „Was?“, „Warum?“ und „Wie?“ von der Mehrheit der Unternehmen nicht beantwortet werden können.




Abbildung 44: Wissensstand zum Einsatz von ML in der Logistik⁴⁷⁹

Diese Unkenntnis führt dazu, dass viele der notwendigen Voraussetzungen, welche u. a. technische und organisatorische Rahmenbedingungen betreffen, noch nicht in den Unternehmen vorzufinden sind.⁴⁸⁰ Dementsprechend fühlt sich auch **nur ein geringer Teil der Unternehmen gut auf den erfolgreichen Einsatz** von ML in der Logistik vorbereitet – wobei dies gleichermaßen auf Unternehmen ohne und mit bestehenden Anwendungen zutrifft (24 % bzw. 29 %). Der vorab skizzierte Handlungsbedarf ergibt sich daher auch für die Gruppe der Adopter und spiegelt sich in deren bisherigem Vorgehen bei der Umsetzung von ML-Anwendungen wider. Demnach binden 72 % dieser Unternehmen hierzu Dienstleister ein. Neben der externen Unterstützung bei der Entwicklung umfasst dies teilweise auch einen vollständigen Fremdbezug der jeweiligen Systeme (sog. **Build-or-Buy-Entscheidung**). Letzteres wird allerdings vor dem Hintergrund der postulierten Bedeutung von ML – insbesondere bei größeren Anwendungen – von vielen Unternehmen als kritisch angesehen, da das ohnehin gering ausgeprägte Technologiewissen auf diese Weise nicht ausgebaut wird, welches jedoch u. a. zur Bewertung und Wartung der extern bezogenen Systeme sowie zur eigenen Entwicklung weiterer Anwendungen benötigt wird. Auch wurde in diesem Zusammenhang festgestellt, dass für viele Anwendungsfälle in der Logistik aufgrund deren Individualität und Komplexität bisher keine schlüsselfertigen ML-Anwendungen am Markt existieren.

4.3 Fallstudien zu Anwendungsfällen aus der Praxis

Nach der vorausgegangenen branchenweiten Erhebung werden in diesem Unterkapitel vier individuelle ML-Anwendungsfälle aus der Praxis im Rahmen einer Fallstudienforschung untersucht. Die Anwendungsfälle entstammen den durchgeführten Interviews und zeichnen sich

⁴⁷⁹ Eigene Darstellung

⁴⁸⁰ Der Umsetzungsstand der system- und umfeldbezogenen Voraussetzungen für den Einsatz von ML im Logistikmanagement wird in Kapitel 6 beschrieben.

durch einen vergleichsweise fortgeschrittenen Entwicklungsstand der jeweiligen ML-Anwendungen aus, welche bereits alle produktiv in mehreren logistischen Entscheidungsprozessen eingesetzt werden. Bei den betreffenden Unternehmen handelt es sich um **je zwei Industrie- und Softwareunternehmen**, wobei die ML-Produkte der beiden letztgenannten auch von mehreren Kunden aus der Industrie genutzt werden. Das Analysespektrum der Fallstudien umfasst sowohl die jeweils realisierten ML-Anwendungen als auch die damit verbundenen projektbezogenen und -übergreifenden Umsetzungsaktivitäten in den Unternehmen. Durch die Einbeziehung der zwei Akteursrollen in Form von Anwendern und Anbietern konnte dabei eine unterschiedliche Schwerpunktsetzung in Form der Betrachtung der Anwendungen oder des Umfeldes vorgenommen werden.

Die anhand der Fallstudien gewonnenen Erkenntnisse dienen der **Verständnis- und Theoriebildung** zum vorliegenden Untersuchungsfeld. Dies bezieht sich zum einen auf den Praxisstand im Sinne der Zielsetzung des vorliegenden Kapitels. Zum anderen stellen sie eine wichtige Grundlage für die Beantwortung der nachfolgenden Forschungsfragen dar, insbesondere zur Ermittlung der Anwendungsmöglichkeiten von ML im Logistikmanagement („Was?“), der resultierenden Auswirkungen („Warum?“) und von geeigneten Umsetzungsmaßnahmen („Wie?“). Diese intendierten Einsatzzwecke spiegeln sich auch in der gewählten Struktur zur Ergebnisdarstellung in diesem Unterkapitel wider. Ausgehend von einer Beschreibung der vier Fallstudien erfolgt zum Abschluss eine Zusammenfassung in Hinblick auf die einzelnen Untersuchungsbereiche.

Die Fallstudien sind in drei Teile strukturiert. Nach einer prägnanten Vorstellung des jeweiligen Unternehmens werden im ersten Teil die **strategischen Aktivitäten** des Unternehmens in Bezug auf ML beschrieben. Im zweiten Teil werden anhand einer spezifischen ML-Anwendung **Maßnahmen zur Gestaltung des Technologieeinsatzes** dargestellt. Ausgehend vom Umsetzungsstand zum Zeitpunkt der Interviewdurchführung werden dabei auch geplante Veränderungen berücksichtigt, z. B. zur technischen Erweiterung und prozessualen Skalierung. Im dritten Teil werden die durch den Einsatz der Anwendungen realisierten **Auswirkungen** sowie darüberhinausgehende Einschätzungen der Unternehmen in Bezug auf ML analysiert, was direkte Veränderungen für logistische Entscheidungsprozesse sowie resultierende betriebswirtschaftliche Potenziale und Risiken umfasst. Letzteres impliziert zudem bedeutende **Herausforderungen**, die für einen erfolgreichen Technologieeinsatz bewältigt werden müssen.

4.3.1 Anwendungsfall 1: Ermittlung des mittelfristigen Materialbedarfes

Einsatz von ML im Unternehmen

Der Anwendungsfall 1 bezieht sich auf ein global agierendes Industrieunternehmen, welches u. a. Produkte im Bereich der Elektrotechnik entwickelt und produziert. In dem Unternehmen kommen bereits mehrere ML-Anwendungen zum Einsatz. Analog zu den branchenweiten Beobachtungen ist jedoch auch in diesem individuellen Fall ein geringerer Umsetzungsstand für

die Logistik gegenüber anderen Funktionsbereichen festzustellen. ML wurde allerdings bereits von der Unternehmensführung als eine Schlüsseltechnologie für die Logistik identifiziert, was auch zu deren **Verankerung in der strategischen Planung** führt. Auf Grundlage einer Auseinandersetzung mit den technologischen Fähigkeiten und einer Analyse aller logistischen Entscheidungsprozesse des Unternehmens wurde eine „Digitale Roadmap“ entwickelt, welche die zukünftigen Bestrebungen zum Einsatz von ML in der Logistik beinhaltet. Dies umfasst eine Darstellung von Entscheidungsprozessen, welche zukünftig „vollautomatisch“ ausgeführt werden sollen – in Verbindung mit einem vorgegebenen Zeitplan, Empfehlungen zur Umsetzung im Sinne eines Soll-Konzeptes sowie angestrebten wirtschaftlichen Zielen. Das Unternehmen zielt hierbei auf eine systemseitige Übernahme von ca. 80 % der operativen Entscheidungen ab. Beim restlichen Teil handelt es sich insbesondere um Sonderprozesse, die in Form eines „Exception Handlings“ weiter durch den Menschen auszuführen sind. Zur Entwicklung der ML-Anwendungen arbeitet das Unternehmen sowohl mit dem internen IT-Bereich als auch mit externen IT-Partnern zusammen, wozu kleinere spezialisierte Unternehmen sowie große Technologieanbieter gehören, z. B. Amazon Web Services, IBM oder SAP.

ML-Anwendung und deren Umsetzung

Bei der betrachteten ML-Anwendung handelt es sich um ein System zur Ermittlung der zukünftigen Bestellmenge der Kunden des Unternehmens in einem Zeitraum von 12 Monaten für mehrere Produkte und Märkte, d. h. um eine Variation des Demand Forecasting. Das System wird bereits produktiv in mehreren Werken eingesetzt – vorwiegend für den Prozess des **Sales and Operations Planning** (S&OP), aber auch für die Produktions- und Beschaffungsplanung, um u. a. die Sicherheitsbestände, Nachschubzyklen und Produktionstermine zu bestimmen. Aus systemtechnischer Sicht handelt es sich um eine **separate Anwendung**, für deren bisherige Ergebnisdarstellung allerdings ein bestehendes Frontend der BI-Anwendung „Qlik View“ genutzt wird. Die ML-Modelle basieren auf Boosting-Verfahren aus dem Bereich des Ensemble-Learning. Als Datenquelle fungieren verschiedene interne Daten, die über einen internen **Data Lake** auf Basis von SAP HANA bezogen werden. Darüber hinaus werden auch externe Daten, wie Wetterinformationen, berücksichtigt.

Über die genannten Anwendungsbereiche hinaus strebt das Unternehmen einen Einsatz des Systems für weitere Entscheidungsprozesse an – mit dem langfristigen Ziel die systemseitigen Informationen für den gesamten produktbezogenen Planungsprozess zu nutzen, u. a. zur Sekundärbedarfs-, Qualitäts- und Instandhaltungsplanung. Zusätzlich soll die Anwendung perspektivisch auch für weitere Produkte und Märkte eingesetzt werden, was jedoch eine Anpassung der Modelle erfordert. Neben dieser prozessualen Skalierung wird auch eine technische Weiterentwicklung verfolgt, indem u. a. neue Daten bzw. Features integriert werden, wie der ifo-Geschäftsklimaindex. Die Anwendung wird aktuell als reine Entscheidungsunterstützung eingesetzt, wobei hier aufgrund der bereits hohen Ergebnisqualität die Sichtweise vertreten wird, dass eher das **System die menschlichen Entscheidungen validiert** als andersherum.

Zukünftig sollen die Entscheidungen zudem autonom ausgeführt werden, sodass die systemseitigen Ergebnisse in unmittelbaren Aktionen münden. Hierzu ist eine Anbindung an die Auftrags- und Planungssysteme des Unternehmens, z. B. an das MES (Manufacturing Execution System), geplant. Der Mensch soll in diesem Szenario nur noch bei Sonderprozessen eingreifen – wobei auch in solchen Fällen systemseitig verschiedene Entscheidungsalternativen vorgegeben werden.

Das als „**U-Boot-Entwicklung**“ (Bootlegging) innerhalb des Logistikbereiches gestartete Projekt wurde zunächst für einen dedizierten Anwendungsfall geplant. Nach den erfolgversprechenden Ergebnissen und der damit verbundenen Kenntnis durch die Unternehmensführung erhielt das Projekt eine finanzielle Förderung, ohne die eine weitere Skalierung nicht möglich gewesen wäre. Für die Weiterentwicklung des Systems zur Nutzung in weiteren Werken hat der Logistikbereich weiterhin die Verantwortung erhalten, wofür mehrere diesbezügliche Personalstellen geschaffen wurden. Parallel werden bereits die späteren Nutzer im Umgang mit der Anwendung geschult.

Auswirkungen und Herausforderungen

Die Motivation zur Entwicklung der ML-Anwendung ergab sich aus einer hohen Unsicherheit über die Nachfrage der Kunden, die gleichzeitig hohen kundenseitigen Erwartungen an die logistische Servicequalität und die Preise gegenübersteht. Dieser Problematik konnte mit der Anwendung begegnet werden, da deren Ergebnisqualität die bisherigen Möglichkeiten deutlich übertrifft. Das Unternehmen ist nun in der Lage, die zukünftige Kundennachfrage **zuverlässiger und in einer höheren Frequenz** zu bestimmen, wodurch die eigenen Bestände vorausschauend angepasst werden können. Dies betrifft zuvorderst eine Reduktion der Sicherheitsbestände, welche zur Kompensation von Fehlkalkulationen vorgesehen sind. Gleichzeitig werden auch Obsoletebestände vermieden, da langfristig sinkende Nachfragen nach bestimmten Produkten antizipiert werden können. Im bisherigen Einsatzzeitraum wurden dadurch die **Bestandskosten um 4 bis 5% reduziert**. Weiterhin war es auch möglich, die Nachschubzyklen zu reduzieren, was sich positiv auf die Anzahl der durchzuführenden Transporte auswirkt. Durch die zukünftige Ausweitung der Anwendung auf weitere Produktionsprozesse wird sich außerdem eine stärkere **Harmonisierung von logistischen und produktionseitigen Anforderungen** erhofft.

Über die spezifische Anwendung hinaus erachtet das Unternehmen ML grundsätzlich als bedeutende Möglichkeit zur Erhöhung der Produktivität, indem bestimmte Aufgabenspektren, v. a. repetitive Aktivitäten, automatisiert und dadurch bedeutende **Kosteneinsparungen** realisiert werden. ML-Anwendungen können daher einen wichtigen Beitrag zur Sicherung von Industriestandorten in Deutschland leisten. Neben den direkten wirtschaftlichen Vorteilen werden auch die Verbesserung der Ergebnisqualität durch die Realisierung von **Entscheidungen abseits von menschlichen Emotionen** sowie die damit verbundene Geschwindigkeit als wichtige technologische Potenziale angesehen. Zusätzlich zum autonomen Einsatz der Sys-

teme wird auch die **Erhöhung der Transparenz** zur Verbesserung menschlicher Entscheidungen, einschließlich der o. g. systemseitigen Validierung, mit einem hohen Nutzen für die Logistik assoziiert.

Als nicht unerhebliches Risiko nimmt das Unternehmen eine teilweise **eingeschränkte Akzeptanz der Mitarbeiter** bei der Nutzung der Anwendung wahr, weshalb es geeigneter Maßnahmen zum Change Management und zum diesbezüglichen Aufbau einer „Union der Willigen“ auf allen Unternehmensebenen bedarf. Die personellen Widerstände, welche v. a. auf den vermuteten Abbau von Arbeitsplätzen zurückgehen, zeigen sich aus Unternehmenssicht nicht nur bei den direkt betroffenen Personen, sondern auch in Form des **Betriebsrates**. Als bedeutende technische Herausforderung wird die Datenqualität angesehen, die für viele infrage kommende Anwendungsfälle in der Logistik als unzureichend betrachtet wird. Vor diesem Hintergrund setzt das Unternehmen ein separates Team in Form eines „Digital Office“ ein, welches sich dezidiert der Verbesserung von Daten widmet.

4.3.2 Anwendungsfall 2: Ermittlung der zukünftigen Produktqualität

Einsatz von ML im Unternehmen

Das Unternehmen des Anwendungsfalls 2 ist hauptsächlich als Produzent von Komponenten und Systemlösungen für eine Vielzahl von Industrieanwendungen tätig, u. a. im Automobilbereich. ML wird auch in diesem Fall als **Schlüsseltechnologie** betrachtet und ist bereits – im Kontext einer Gleichsetzung mit KI – in der strategischen Roadmap des Unternehmens integriert. Für den Technologieeinsatz wird hierbei jedoch eine **lösungsoffene Strategie** verfolgt, die eine problemspezifische Bewertung der jeweils geeignetsten Technologie für eine Problemstellung vorsieht. Vor diesem Hintergrund existiert auch keine technologiespezifische Vision im Logistikumfeld, sondern vielmehr ein übergreifendes Zielbild, welches eine vollständige virtuelle Repräsentation der realen Umgebung des Unternehmens, u. a. der Fabrik und der Produkte, in Form von digitalen Zwillingen bzw. **Digital Twins (DT)**⁴⁸¹ beinhaltet. Die DT sollen im vorliegenden Fall auch eine Grundlage für neue Services gegenüber internen und externen Kunden bieten, z. B. durch die Bereitstellung von Qualitäts- oder Geometriedaten zur Rückverfolgbarkeit oder durch die Ermittlung zukünftiger Produktausfälle. Für die Realisierung der einzelnen Funktionen der angestrebten DT des Unternehmens nimmt ML eine wichtige Rolle ein. Die Umsetzung der ML-Anwendungen wird dabei durch das Unternehmen hauptsächlich selbst verantwortet, wobei kein dediziertes ML-Team existiert, sondern die Technologie von jedem Entwicklungsbereich innerhalb der IT als ein möglicher Lösungsansatz verwendet werden kann. Dazu wurden spezialisierte Mitarbeiter einer vorab bestehenden externen Organisationseinheit für innovative Vorhaben („Lab“) **in den IT-Bereich eingegliedert**, was

⁴⁸¹ Bei dieser Schlüsseltechnologie werden durch Konsolidierung und Aufbereitung von unterschiedlichen Daten digitale Abbilder geschaffen, welche den Nutzern die Möglichkeit bieten, mithilfe von Analysen und Simulationen eine zielgerichtete Anpassung und Optimierung der realen Welt durchzuführen. Vgl. Busse et al. (2021), S. 9 f.

als bedeutender Fortschritt auf dem Weg zur digitalen Transformation des Unternehmens erachtet wird. Die Finanzierung von ML-Projekten erfolgt dabei mittels eines dedizierten Digitalisierungsbudget durch die Unternehmensführung. Zur kooperativen Wissensgenerierung im Bereich von DT und ML arbeitet das Unternehmen zudem mit Forschungseinrichtungen im Sinne eines **Open-Innovationen-Ansatzes** zusammen.

ML-Anwendung und deren Umsetzung

Die untersuchte ML-Anwendung dient der Ermittlung der voraussichtlichen Qualität von bestimmten Produkten in Form des akustischen und schwingungstechnischen Verhaltens von Unterbaugruppen im technischen Zielsystem der Kunden. Das bereits in Betrieb genommene System wird im Rahmen der Qualitätskontrolle des End-of-Line-Prüfstands verwendet. Für das ML-Modell wurde nach Testungen mehrerer Verfahren ein Random-Forest-Algorithmus ausgewählt, der v. a. Daten aus den jeweiligen Prüfprozessen der fertigen Produkte berücksichtigt und eine Klassifikation der Qualität anhand einer Skala von eins („sehr schlecht“) bis zehn („sehr gut“) vornimmt. Liegt der prognostizierte Wert unterhalb einer definierten Schwelle, wird das Produkt als Nonconformity-Material (NC) ausgeschleust und nicht zum Kunden weitergegeben. Zusätzlich findet auf dieser Grundlage eine Analyse von Fehlerursachen statt, die in Anpassungen der Fertigungsprozesse, aber auch der Produktgestaltung münden können. Die Ableitung der Maßnahmen findet aktuell manuell statt, soll aber in Zukunft für das **Aussteuern fehlerhafter Produkte autonom** erfolgen.

Aktuell werden die ML-Anwendung bzw. das zugrundeliegende Modell als Bestandteil bestehender IT-Systeme in der Produktion eingesetzt. Zukünftig soll eine **systemtechnische Integration in die Digital Twins** erfolgen, sodass die Ergebnisse des ML-Modells – zusammen mit anderen Funktionen – als Service von verschiedenen internen und externen Kunden abgerufen werden können und somit eine hohe Skalierbarkeit sichergestellt wird. Neben der Darstellung im jeweiligen Zielsystem sind die Ergebnisse der ML-Modelle perspektivisch auch über eigene Dashboards der DT abrufbar. Die systemseitige Ausführung erfolgt in diesem Fall mittels externer Cloud-Infrastruktur, welche als Infrastructure-as-a-Service (IaaS) von Microsoft Azure bezogen wird. Neben einer höheren Performance gegenüber einer lokalen Verarbeitung werden mit diesem Ansatz die Vorteile einer besseren technischen Integration, Überwachung und Wartung assoziiert.

Zur Gewährleistung einer skalierbaren Anwendung wurden bei der Entwicklung von Beginn an unterschiedliche prozessuale und technische Anforderungen berücksichtigt. Hierzu erfolgt auch eine Einbindung der betroffenen Kunden, welche zusätzlich Domänenwissen zum Verhalten der Produkte in den jeweiligen Zielsystemen bereitstellten. Für den Entwicklungsprozess wurde ein agiles Vorgehen gewählt, u. a. unter Nutzung der SCRUM-Methode, bei dem ausgehend von der hohen Komplexität des Gesamtsystems eine Umsetzung in kleinen Schritten unter regelmäßiger Bewertung durch die Kunden stattfand, sodass deren Anforderungen berücksichtigt und Fehler frühzeitig erkannt werden konnten. Zur Steigerung der Transparenz

und Akzeptanz im Betrieb der Anwendung wurden mit den involvierten Mitarbeitern **Schulungen** durchgeführt, die u. a. eine Erklärung von KI und ML beinhalteten, mit dem Ziel, diese Themen zu „entmystifizieren“.

Auswirkungen und Herausforderungen

Die ML-Anwendung führt in erster Linie zu einer Reduktion der Nacharbeit beim Kunden und damit zu einer höheren Kundenzufriedenheit sowie zur Vermeidung von Pönalen. Zudem können auf Grundlage identifizierter Fehler die Produktionsprozesse und die **Qualität zukünftiger Produkte zielgerichteter und schneller verbessert** werden, ohne dass es größerer Iterationsschleifen mit den Kunden bedarf. Die antizipative Erkennung von Ausschüssen trägt ferner zur **ökologischen Nachhaltigkeit** bei, da die Qualitätsnachweise zu den Produkten nicht erst am Wareneingang der Kunden, sondern bereits vor der Auslieferung erbracht werden, was zur Reduzierung von Retouren beiträgt.

Analog zu der bereits realisierten Anwendung sieht das Unternehmen auch die grundsätzlichen Potenziale von ML in der **Verbesserung der Entscheidungsfindung** bei Problemen mit vielen Wirkungszusammenhängen – welche von den bisherigen modellbasierten Ansätzen nicht zufriedenstellend gelöst werden konnten. In diesem Zusammenhang wird ML auch als bedeutende Möglichkeit zur **Autonomisierung von Entscheidungsprozessen** erachtet. Neben der damit verbundenen Reduktion von Personalkosten wird darin auch eine Chance zur Veränderung des Aufgabenspektrums der Mitarbeiter hin zu anspruchsvolleren Tätigkeiten gesehen. Ein weiteres Potenzial ergibt sich für das Unternehmen in der Realisierung neuer Funktionen und **produktbezogener Services**, die externen Kunden angeboten werden können und zur Differenzierung gegenüber Wettbewerbern beitragen.

Als hohes Risiko bei der Umsetzung wird die **fehlende Akzeptanz der Anwendungen** angesehen, wobei sich dies sowohl auf die Nutzergemeinschaft als auch auf die Unternehmensführung bezieht. Neben einer eingeschränkten Kenntnis über die Technologie und einem damit verbundenen Misstrauen wird dieses Risiko v. a. mit der **Auswahl ungeeigneter Anwendungsfälle** begründet. Bei dem mittels ML adressierten Problem sollte es sich demnach aus Sicht des Unternehmens stets um ein bedeutendes betriebliches Defizit handeln, durch dessen Lösung deutliche Verbesserungen zu erwarten sind. Auf der anderen Seite werden aber auch **hohe Erwartungen** bei einigen Organisationsmitgliedern beobachtet, welche sich sowohl auf die erzielbaren Potenziale als auch auf benötigten Aufwand bei der Umsetzung beziehen. Eine weitere zentrale Herausforderung bezieht sich auf die notwendigen Daten, die – wie im Falle der beschriebenen Anwendung – nicht nur aus unternehmensinternen Systemen stammen. Es bedarf zum einen der bereitwilligen Erfassung und Speicherung der relevanten Daten durch die eigenen Fachbereiche, was jedoch aufgrund des damit verbundenen Aufwands nicht immer konsequent verfolgt wird. Zum anderen zeigt sich im Falle der Kunden häufig ein **Misstrauen bei der Bereitstellung** der benötigten externen Daten.

4.3.3 Anwendungsfall 3: Multi-Echelon-Bestandsoptimierung

Einsatz von ML im Unternehmen

Der Anwendungsfall 3 bezieht sich auf ein weltweit operierendes IT-Unternehmen, welches Software im Bereich der Logistik bzw. dem SCM entwickelt sowie zusätzlich die jeweiligen Kunden aus Handel und Industrie bei der Systemeinführung berät. Die Produkte werden häufig als Software-as-a-Service (SaaS) durch die Kunden bezogen. In mehreren Lösungen wird bereits ML eingesetzt, welche als bedeutende Technologie für das eigene Geschäft angesehen wird. Vor diesem Hintergrund engagiert sich das Unternehmen auch in der **Entwicklung neuer Lernverfahren**. Bei der oft kundenanonymen Produktgestaltung von ML-Anwendungen nutzt das Unternehmen sein jahrelang aufgebautes Domänenwissen, indem Problemstellungen in der Logistik analysiert und notwendige Funktionalitäten mit einem Mehrwert für Kunden in diesem Bereich abgeleitet werden. In den letzten Jahren findet dabei eine **verstärkte Ausrichtung auf Planungs- und Steuerungsaktivitäten** statt, da diese aus Sicht des Unternehmens im Kontext von ML bisher deutlich unterrepräsentiert sind. Dies wird mit dem jahrelangen Fokus der Kunden auf die systemseitige Unterstützung von ausführenden Tätigkeiten begründet, insbesondere in Bezug auf das autonome Fahren.

ML-Anwendung und deren Umsetzung

Die analysierte ML-Anwendung weist zwei aufeinander aufbauende Funktionen auf, welche die Ermittlung der zukünftigen Absatzmenge eines Produktes und die darauf basierende Bestimmung einer geeigneter Bestellmenge und eines geeigneten Bestellzeitpunktes umfassen. Letzteres berücksichtigt verschiedene Zielgrößen und Restriktionen, u. a. die Reduzierung von Kosten, aber auch die Vermeidung von Lieferengpässen (Out-of-Stock-Situationen) und Obsoletbeständen. Hierbei wird ein **Multi-Echelon-Ansatz** umgesetzt, der eine Optimierung von Beständen entlang mehrerer Stufen und/oder Standorte eines logistischen Netzwerkes vorsieht, sodass aus „globaler“ Perspektive eine bestmögliche Lösung ermittelt wird. Im vorliegenden Anwendungsfall umfasst das u. a. eine Berücksichtigung der individuellen Bestandsituation sowie der notwendigen Lager- und Lieferzeiten an mehreren Distributionsstandorten der Kunden. Anders als bei den bisherigen Anwendungsfällen werden zudem die systemseitigen Ergebnisse nicht als einzelner Wert ausgegeben, sondern in Form mehrerer **Szenarien für unterschiedliche Ausprägungen** der Absatzmenge mit individuellen Wahrscheinlichkeiten. Zusätzlich wurde hierzu auch die Funktion einer manuellen Generierung von Szenarien implementiert, bei der Restriktionen, wie der Preis, durch den Nutzer angepasst werden können, sodass auf Basis dieser fiktiven Voraussetzungen eine Bestimmung der zukünftigen Absatzmenge stattfindet. Die Anwendung wird bei den Nutzern primär für die **Bestandsplanung** eingesetzt, aber teilweise auch für die Lieferantensteuerung sowie für vertriebliche Aktivitäten. Zur Realisierung der ML-Modelle der Anwendung wurde ein selbstentwickelter Ansatz verwendet, welcher u. a. auf Boosting-Verfahren basiert und eine gegenüber anderen Anwendungen verbesserte **Interpretierbarkeit des Lösungsweges** für die Nutzer sicherstellen soll, indem

u. a. die Relevanz einzelner Features ausgegeben wird. In Hinblick auf eine hohe systemseitige Skalierbarkeit, die einen besonderen Stellenwert für das Unternehmen einnimmt, werden verschiedene Entwicklungskonzepte aus dem Bereich des Transfer Learning⁴⁸² verfolgt. Hierdurch sollen die Modelle auf Grundlage von Anwendungsfällen zu Produkten mit vielen Daten auch zuverlässige Ergebnisse für Anwendungsfälle zu Produkten mit wenigen oder sogar keinen Daten generieren können. Eine weitere skalierungsbezogene Maßnahme ist die **Bereitstellung der Anwendung als SaaS** (Software as a Service) auf Basis einer Microsoft Azure Cloud, wodurch entwicklungsseitige Anpassungen bei allen Kunden ohne Verzögerung und ohne individuellen Implementierungsaufwand verfügbar gemacht werden können. Die Cloud-Umgebung ermöglicht dem Unternehmen zudem eine hohe Sicherheit gegenüber externen Manipulationen, eine hohe Konformität zur Datenschutz-Grundverordnung (DSGVO) sowie einen geschützten Datenaustausch.

Das Unternehmen verfolgt eine kontinuierliche Verbesserung der Anwendung, was zum einen die Modelle und verwendeten Lernverfahren betrifft. Hierzu führt die Entwicklungsabteilung regelmäßig **Benchmarkings mit anderen Anwendungen** und fachliche Diskussionen mit der Forschungscommunity durch. Zum anderen beziehen sich die Verbesserungen auf regelmäßige **Erweiterungen der Anwendung um neue Funktionen**, wie bspw. im Zusammenhang mit der COVID-19-Pandemie und diesbezüglicher Störungen in den Lieferketten. Der Einsatz der realisierten Anwendung erfolgt bei den meisten Kunden in Form einer Entscheidungsunterstützung. Dabei werden die Nutzer auch **zur Bewertung der systemseitigen Ergebnisse unterstützt**, indem sie Ausreißer mit Zusatzinformationen im Frontend angezeigt bekommen. Diese potenziellen Fehler werden durch Prüfungen anhand vordefinierter Restriktionen, u. a. in Form von Preis- und Bestandsregeln, durch das System detektiert.

Auswirkungen und Herausforderungen

Mithilfe der ML-Anwendung lassen sich die voraussichtlichen kundenseitigen Bedarfe von Produkten zuverlässig ermitteln und darauf basierend möglichst geringe Bestände unter Sicherstellung der Lieferfähigkeit innerhalb eines gesamten Logistiknetzwerkes realisieren. Dies führt zu einer optimalen Verteilung von Produkten über mehrere Standorte und Stufen und damit auch zur Reduzierung des Bullwhip-Effekts, d. h. den Schwankungen von Bestellmengen entlang der Lieferkette. Als bedeutender logistischer Kostentreiber können dadurch die **Bestandskosten der Unternehmen vermindert** werden. Entsprechend der regelmäßigen systemseitigen Neuberechnung, die im Rahmen einer manuellen Ausführung aufgrund der Problemkomplexität nicht zuverlässig möglich ist, können die Unternehmen mithilfe der Anwendung auch **Veränderungen in dynamischen Märkten antizipieren** und ihre Bestände, Prozessabläufe und Preise dahingehend vorausschauend anpassen.

⁴⁸² Eine Erklärung dieses Ansatzes erfolgt im Rahmen der Forschungstrends in Kapitel 4.4.1.

Im Einklang mit den Potenzialen der spezifischen Anwendung erachtet das Unternehmen ML als bedeutende Technologie zur Erhöhung der Qualität von logistischen Entscheidungsprozessen. In diesem Kontext wird auf die COVID-19-Pandemie verwiesen, die stärker als bisher bewiesen hat, dass individuelle Heuristiken von Entscheidungsträgern in Form eines „Bauchgefühls“ versagen, wohingegen **ML-Anwendungen schnell neue Zusammenhänge erlernen** – sowie diese durch manuelle Eingriffe in Form einer bewussten Anpassung der Trainingsdaten auch schnell wieder „verlernen“ können. Ein weiteres Potenzial von ML wird in der **Verbesserung der ökologischen Nachhaltigkeit** gesehen, welches jedoch bisher nur von wenigen Anwendungen am Markt adressiert wird.

Analog zu den beiden vorausgegangenen Anwendungsfällen werden auch durch das vorliegende Unternehmen „Berührungspunkte“ von Personen gegenüber ML-Anwendungen wahrgenommen, welche sich in einer vollkommenen Ablehnung äußern können. Dieses Verhalten steht aus Sicht des Unternehmens im Zusammenhang mit der Überzeugung vieler Mitarbeiter, dass menschliche Entscheidungen den systemseitigen Ergebnissen überlegen sind, wobei jedoch oftmals eine **Unkenntnis über die genauen Fähigkeiten und Potenziale** von ML zu beobachten ist. Auf der anderen Seite wird aber auch eine höhere Akzeptanz bei den Digital Natives wahrgenommen. Weitere wichtige Hemmnisse beziehen sich aus Sicht des Unternehmens auf die **homogene Zusammensetzung von ML-Projektteams** sowie auf einen fehlenden Bezug der Anwendungen zu bedeutenden Problemen der jeweiligen Unternehmen, woraus häufig eine mangelnde Unterstützung der Unternehmensführung resultiert. In diesem Zusammenhang wird auch auf das **Fehlen genauer Zielvorgaben** und geeigneter Evaluierungsverfahren verwiesen, die u. a. einen eingeschränkten Problembezug sowie andere technische Defizite frühzeitig aufdecken könnten.

4.3.4 Anwendungsfall 4: Detektion von Risiken in globalen Lieferketten

Einsatz von ML im Unternehmen

Bei dem Unternehmen des Anwendungsfalls 3 handelt es sich um einen Anbieter von spezialisierter Software für die Transparenzerhöhung in Lieferketten, z. B. im Automobilbereich. Ziel der Produkte, welche als SaaS angeboten werden, ist die Aufdeckung von Risiken in den Wertschöpfungsnetzwerken der Kunden, um die Einhaltung unternehmensinterner und -externer Vorgaben zu überwachen, wie spezifische Verhaltenskodizes (Code of Conduct) und das Lieferkettensorgfaltspflichtengesetz (LkSG). Gleichzeitig sollen die Systeme zu einer gezielten Verbesserung der Lieferketten beitragen. Dies bezieht sich neben der Sicherstellung der Lieferfähigkeit v. a. auf Themen der sozialen Nachhaltigkeit (CSR), indem bspw. Fälle von Kinderarbeit bei Zulieferern detektiert werden. ML wird bereits in mehreren Produkten eingesetzt und nimmt für das Unternehmen eine **hohe Bedeutung bei der Gestaltung zukünftiger Lösungen** ein. Neben den damit realisierbaren technologischen Potenzialen resultiert diese Sichtweise aus der wahrgenommenen hohen Nachfrage nach ML- bzw. KI-basierten Lösungen bei den Kunden.

ML-Anwendung und deren Umsetzung

Die betrachtete ML-Anwendung detektiert lieferantenbezogene Risiken in globalen Wertschöpfungsnetzen. Es handelt sich dabei insbesondere um Risiken, die nicht oder nur verzögert von den Lieferanten an deren Auftraggeber weitergegeben werden, wie betriebliche Störungen, z. B. infolge von Naturkatastrophen, Industrieunfällen und Streiks, finanzielle Risiken, z. B. Insolvenzausfälle, sowie Nachhaltigkeitsrisiken, z. B. die Verletzung von Menschenrechten. Aktuell ermöglicht die Anwendung eine Überwachung von ca. 5.000 Lieferanten, wobei dies bis auf die Stufe der Rohstofflieferanten, z. B. in Form von Minenbetreibern, realisiert werden kann. Die Grundlage für die Anwendung bilden **öffentliche Datenquellen**, die sich aus Social-Media-Daten, u. a. von Twitter, Facebook und WeChat, aus Informationen von Zeitungen und lokalen Handelsblättern sowie aus Informationen anderer Webseiten, wie Blogbeiträge von Nichtregierungsorganisationen und Unternehmenswebseiten, zusammensetzen. Aufgrund der öffentlichen Verfügbarkeit bedarf es keiner Einwilligung der überwachten Lieferanten zur Einbindung dieser Daten. Das aktuelle System verfügt über mehr als 50 Sprachen, sodass die Analyse der Datenquellen in der jeweiligen Landessprache ohne deren Übersetzung stattfinden kann, wodurch fehlerhaften Risikomeldungen aufgrund etwaiger Übersetzungsfehler entgegengewirkt wird.

Basierend auf festgelegten Schlüsselwörtern und damit verbundenen inhaltlichen Kontexten werden durch die Anwendung mehrere Millionen Daten in Echtzeit überprüft und Wahrscheinlichkeiten für das Vorliegen bestimmter Risiken ermittelt. Im Falle einer Überschreitung vordefinierter Grenzen wird ein Alarm ausgelöst, sodass die Kunden geeignete Maßnahmen zur Mitigation der Ereignisse einleiten können. Ereignisse mit einer geringeren Wahrscheinlichkeit werden zudem als „Gerüchte“ mit der zugrundeliegenden Datenquelle ausgewiesen. Im Falle eines unbegründeten Risikos können diese Informationen durch die Nutzer als „unwichtig“ bewertet werden, was zu einer **Rückkopplung an die Systeme** und einer Berücksichtigung beim Re-Training führt. Die Informationen der ML-Anwendung werden aktuell durch die Kunden als **Entscheidungsunterstützung** für Planungs- und Steuerungsaktivitäten eingesetzt. Der Anwendungsbereich reicht dabei vom klassischen Einkauf zur Steuerung und Auswahl von Lieferanten über die Bestandsplanung zur Anpassung von Sicherheitsbeständen bis hin zur Nutzung in Nachhaltigkeitsabteilungen und der Unternehmensführung, u. a. zur Bestimmung von CSR-Indikatoren. Darüber hinaus fließen die Informationen auch direkt in andere kundenspezifische ML-Anwendungen ein, wie z. B. zur Bestimmung von Ankunftszeiten für Transporte in Form der ETA (Estimated Time of Arrival).

Das System wird über eine unternehmenseigene Plattform angeboten, welche auf der Google Cloud basiert und deren Funktionen und Nutzeroberfläche kundenspezifisch angepasst werden können. Diese Bereitstellungsform bietet den Kunden eine hohe Verfügbarkeit und den benötigten Datenschutz. Außerdem ist auch eine Übertragung zentraler Informationen in lokale Systeme der Kunden mittels API (Application Programming Interfaces) möglich. Die Informationen zu lieferantenbezogenen Risiken sind dabei grundsätzlich für alle Unternehmen

gleichermaßen verfügbar. Die Anwendung und die zugrundeliegende Plattform sowie das diesbezügliche Geschäftsmodell sind unter der Zielstellung einer ausgeprägten **Skalierung** konstruiert. Hierzu wird auch die Realisierung des Netzwerkeffektes verfolgt, indem durch jeden weiteren Kunden und dessen Lieferanten das Analysespektrum der Anwendung erweitert wird – wovon wiederum alle anderen Nutzer profitieren.

Auswirkungen und Herausforderungen

Die beschriebene ML-Anwendung trägt wesentlich zur **Verbesserung der Transparenz** von Lieferketten der jeweiligen Unternehmen bei. Die in diesem Zusammenhang verarbeitete Informationsvielfalt kann weder von Menschen noch von bisherigen systemseitigen Ansätzen in dem Umfang und in der Güte erfasst und bewertet werden. In Bezug auf alternative Lösungen hat das Unternehmen auch entsprechende Benchmarks durchgeführt, die zu dem Ergebnis führten, dass durch die eigene Anwendung eine 17-mal höhere Informationsmenge berücksichtigt wird. Ein weiterer Vorteil, v. a. gegenüber der manuellen Ausführung, ergibt sich durch die hochfrequente bzw. in diesem Fall permanente Überwachung von Prozessen, wodurch – in Kombination mit den ebenfalls ausgegebenen Ursachen für diese Ereignisse – die **Reaktions- und Durchlaufzeit von Entscheidungen verkürzt** werden. Infolge der Überwachungsfunktion der Anwendung können bei den Kunden zudem mehrere Tätigkeiten des Risikomanagements von Lieferketten automatisiert werden. Durch die daraus resultierende Möglichkeit zur Reduzierung des Personalaufwands erhoffen sich die Unternehmen größere **Kosteneinsparungen**. Weitere Effizienzsteigerungen werden durch die Vermeidung kritischer Ereignisse in Form von Produktionsstillständen und Lieferausfällen realisiert, die mithilfe der Anwendung frühzeitig erkannt werden. Diese indirekten Einsparungen durch bessere Entscheidungen werden jedoch bisher nicht von den Kunden im vollen Maße wahrgenommen. Ein weiteres wichtiges Potenzial der Anwendung stellt die **Steigerung der Robustheit von Lieferketten** dar, wobei auch in diesem Fall auf die COVID-19-Pandemie verwiesen wurde, welche den Bedarf an Systemen zur frühzeitigen Detektion von Störungen erheblich erhöht hat.

Als eine zentrale Herausforderung beim Einsatz von ML-Anwendungen wird die quantitative Erfassung von Kosteneinsparungen im Falle einer Verbesserung der Transparenz und der Entscheidungsqualität gesehen, wodurch wichtige Potenziale bei der Business-Case-Erstellung unberücksichtigt bleiben. Dies kann letztlich zu Entscheidungen gegen die Umsetzung von entsprechenden Anwendungen führen. Zudem wird auch in diesem Fall auf die kritische Einstellung vieler Personen gegenüber ML hingewiesen, die sich teilweise zudem in **unrealistisch hohen Ansprüchen** äußert. Es wird in diesem Zusammenhang aber auch davon ausgegangen, dass sich die Wahrnehmung von ML-Anwendungen als potenzielle Gefahr für den eigenen Arbeitsplatz bei vielen Mitarbeitern mittelfristig verändert, indem diese als objektive Unterstützung der menschlichen Entscheidungen zur **Verbesserung der eigenen Arbeitsbedingungen** betrachtet werden.

4.3.5 Zusammenfassung der Fallstudien

Anhand der vier Anwendungsfälle konnte das für die vorliegende Arbeit benötigte Verständnis zum Praxistand von ML im Logistikmanagement weiter erhöht werden. Gleichzeitig wurden wichtige Erkenntnisse in Hinblick auf die Theoriebildung für die nachfolgenden Schritte des Forschungsprozesses erzielt. Eine Zusammenfassung zentraler fallspezifischer Informationen zu den einzelnen Untersuchungsbereichen findet sich in Tabelle 10. Insgesamt ist festzustellen, dass ML bereits für mehrere Entscheidungsprozesse **in der Logistik nutzenbringend eingesetzt** werden kann. Dies reicht allgemein von einer Wahrnehmung aktueller Probleme über die Ermittlung zukünftiger Ausprägungen von bedeutenden Entscheidungsparametern bis hin zur Bestimmung geeigneter Aktionen für die Optimierung von Logistikprozessen. Die systemtechnische Gestaltungsform von ML entsprach dabei in drei Fällen einer separaten Anwendung; in einem Fall wurden die ML-Modelle in bestehende Systeme zur Bereitstellung einer neuen darauf basierenden Funktion integriert. Dabei haben sich auch Möglichkeiten zur geeigneten Verbindung von ML mit anderen Schlüsseltechnologien in Form von Digital Twins gezeigt. Ausgehend von einer aktuellen Entscheidungsunterstützung in allen Anwendungsfällen ist für mehrere Anwendungen zukünftig ein autonomer Einsatz geplant. Neben schwer messbaren **Verbesserungen der Informationstransparenz und der Entscheidungsqualität**, welche übergreifend zu beobachten waren, konnten durch die Nutzung der Anwendungen auch bedeutende wirtschaftliche Erfolge erzielt werden. Es wurde aber auch deutlich, dass mit dem Einsatz von ML mehrere Herausforderungen einhergehen, die von fehlenden technischen und finanziellen Voraussetzungen bis zu Widerständen bei den Organisationsmitgliedern reichen. Im diesbezüglichen Umgang zeigen sich Gemeinsamkeiten und Unterschiede bei den betrachteten Unternehmen. Ersteres umfasst u. a. eine Verankerung von ML in der strategischen Unternehmensplanung, eine gezielte Identifikation von geeigneten Anwendungsfällen, eine Fokussierung auf die Skalierbarkeit der Anwendungen sowie deren Betrieb auf externer Cloud-Infrastruktur. Unterschiede betreffen u. a. die organisatorische Verantwortung zur Umsetzung von ML-Anwendungen, für die sich sowohl zentrale als auch dezentrale Ansätze zeigen, sowie den Umgang zum Aufbau von Technologiewissen.

Nr. Anwendung („Was?“)	Potenziale („Warum?“)	Maßnahmen („Wie?“)
<p>1</p> <ul style="list-style-type: none"> - Ermittlung der zukünftigen Bestellmenge - Aktuell v. a. für S&OP eingesetzt; zukünftig für gesamten logistischen Planungsprozess - Separate Anwendung mit Frontend von anderem System - Aktuell assistierende Lösung, hierbei auch Validierung der menschlichen Entscheidungen - Zukünftige Anbindung an Auftragsysteme zur autonomen Entscheidungsausführung 	<ul style="list-style-type: none"> - Bedarfsgerechte Auslegung der Prozesse - Reduzierung der Bestandskosten und Nachschubzyklen - Zuverlässigere Entscheidungen mit einer höheren Frequenz - Entscheidungen ohne subjektive Beeinflussung - Erhöhung der Informationstransparenz - Harmonisierung der Anforderungen von Produktion und Logistik 	<ul style="list-style-type: none"> - Vorausgehende Ermittlung von Anwendungsfällen und Überführung in Strategie mit langfristiger Zielsetzung - Skalierung durch finanzielle Unterstützung der Unternehmensführung - Zusammenarbeit mit externen Partnern zur Umsetzung, aber auch eigene Rekrutierung von Fachkräften - Schulung der Nutzer im Umgang - Change Management für Akzeptanz-erhöhung der Mitarbeiter - Verbesserung der Datenqualität durch eigenes Team - Data Lake für Datenintegration
<p>2</p> <ul style="list-style-type: none"> - Ermittlung des zukünftigen Verhaltens von Bauteilen im Zielsystem der Kunden - Nutzung für Qualitätskontrolle - Aktuell in Bestandsysteme der Produktion integriert - Perspektivische Integration als Funktion in Digital Twin mit bereichsübergreifender Bereitstellung als Service - Aktuell als Entscheidungsunterstützung, zukünftig autonome Aussteuerung 	<ul style="list-style-type: none"> - Vorausschauende Erkennung von Fehlern - Reduktion von Nacharbeit und Strafzahlungen - Lösung komplexer Probleme mit vielen Parametern - Automatisierung von Entscheidungen - Grundlage für neue Geschäftsmodelle - Zuweisung von „höheren“ Aufgaben für Mitarbeiter 	<ul style="list-style-type: none"> - Technologieoffene Strategie mit ML als wichtiges Werkzeug - Auflösung der Labs und dezentrale Kompetenzverteilung innerhalb IT - Eigenentwicklung mit Open-Innovation - Agiler Entwicklungsprozess mit regelmäßiger Ergebnisprüfung - Intensive Einbindung von Prozessverantwortlichen für Domänenwissen und Bewertung - Gezielte Auswahl von Anwendungen - Entmystifizierung von ML durch Schulung von Stakeholdern - Nutzung IaaS für Betrieb
<p>3</p> <ul style="list-style-type: none"> - Ermittlung der zukünftigen Absatzmenge und darauf basierende Optimierung von Bestellmengen und -zeitpunkt - Einsatz für Bestandsplanung - Ausgabe von Szenarien für Absatzmenge mit manuellen Gestaltungsmöglichkeiten - Separate Anwendung als SaaS - Einsatz als Entscheidungsunterstützung 	<ul style="list-style-type: none"> - Bedarfsgerechte Planung von Bestellmengen (Reduzierung Bullwhip-Effekt) - Verringerung von Bestandskosten - Anpassungsfähigkeit an neue Problemstellungen bzw. Ereignisse - Erhöhung der Entscheidungsqualität 	<ul style="list-style-type: none"> - Systemseitige Ergebnisprüfungen durch Plausibilitätsregeln - Entwicklung eigener Lernverfahren für höhere Interpretierbarkeit - Hoher Fokus auf Skalierung der Anwendungen, u. a. durch Berücksichtigung mehrerer Anwendungsfälle bei Entwicklung - Einholung externer Anregungen für Verbesserung der Systeme - Nutzung IaaS für Betrieb, u. a. für Datensicherheit und -schutz
<p>4</p> <ul style="list-style-type: none"> - Ermittlung von Risiken und Störungen in Lieferketten - Einsatz zum Lieferantenmanagement und Bestandsplanung - Separate Anwendung als SaaS - Vorwiegend Einsatz als Entscheidungsunterstützung, aber auch direkter Input für andere Systeme 	<ul style="list-style-type: none"> - Sicherstellung der Lieferfähigkeit - Kostenreduktion durch weniger manuelle Aufwände - Umgang mit hoher Informationskomplexität - Reduktion der Reaktions- und Entscheidungszeiten - Verbesserung von Arbeitsbedingungen 	<ul style="list-style-type: none"> - Ergebnisprüfung durch Nutzer und Rückkopplung an System - Skalierbare Gestaltung der Anwendungen, inkl. leichte Anbindung neuer Nutzer - Nutzung öffentlicher Datenquellen, dadurch geringe Beschaffungsbarrieren - Nutzung IaaS für Betrieb, u. a. für Datenschutz und Verfügbarkeit

Tabelle 10: Zusammenfassung der Fallstudienforschung

4.4 Zukünftige Entwicklungen

In diesem Unterkapitel werden relevante Entwicklungen für das vorliegende Untersuchungsfeld beschrieben. Deren Relevanz äußert sich in einem potenziell **unterstützenden oder hemmenden Einfluss** in Bezug auf die Phasen des Adoptionsprozesses von ML-Anwendungen im Logistikmanagement, insbesondere hinsichtlich der Adoptionsentscheidung und konkreter Umsetzungsmaßnahmen. Die identifizierten Entwicklungen werden anhand ihres Entstehungszusammenhangs in Forschungstrends zu ML sowie in darüberhinausgehende Entwicklungen aus dem Umfeld der betrachteten Unternehmen unterschieden, wobei letztere gleichzeitig die vom TOE-Modell geforderte Berücksichtigung unternehmensexterner Einflüsse repräsentieren (siehe Kapitel 2.1.3.2). Trotz dieser vorgenommenen Trennung bestehen weiterhin inhaltliche Schnittmengen und Wirkungszusammenhänge zwischen den einzelnen Entwicklungen.

4.4.1 Forschungstrends zu ML

Ungeachtet der Erfolge in den letzten Jahren existieren für ML weiterhin viele Anknüpfungspunkte für Verbesserungen, welche insgesamt zu sehr dynamischen Forschungsaktivitäten in diesem Bereich führen. Die für die vorliegende Untersuchung bedeutenden Aktivitäten wurden unter Berücksichtigung mehrerer relevanter Veröffentlichungen⁴⁸³ identifiziert und nach ihrem technischen Ansatz in Form der Weiterentwicklung von Lernverfahren und der Verbindung von ML mit anderen Technologien unterschieden. Die ermittelten Trends werden nachfolgend mit ihren Implikationen für das Untersuchungsfeld beschrieben. Vorab findet sich dazu in Tabelle 11 eine Zusammenfassung, aus der auch eine indikative Einschätzung des aktuellen Entwicklungsstandes hervorgeht. Dabei ist zu konstatieren, dass einige der Forschungsaktivitäten bereits zu produktiv einsetzbaren Systemen in der Praxis geführt haben, während andere noch der Grundlagenforschung zuzuordnen sind. Insgesamt wird davon ausgegangen, dass sich im Falle einer produktiven Umsetzung dieser Forschungsaktivitäten die Eigenschaften von ML bzw. der darauf basierenden **Systeme langfristig verbessern**. Dies betrifft insbesondere deren Ergebnisqualität durch eine Weiterentwicklung der Lernverfahren, was zukünftig auch zu zuverlässigeren Lösungen bei Anwendungsfällen mit wenig Daten (sog. **Small Data**) führt. Zudem werden sich in Folge einer höheren **Interpretierbarkeit** der Lernprozesse auch bessere Möglichkeiten zur gezielten Optimierung der Modelle ergeben. Zusätzlich ist von einer erhöhten Sicherheit zukünftiger Systeme und der eingebundenen Daten auszugehen, was gleichzeitig die Möglichkeiten zur **Lösung unternehmensübergreifender Problemstellungen** verbessert. Auch der heutige Engpass von datenintensiven Problemstellungen in Form der benötigten Rechenleistung wird von mehreren Forschungsaktivitäten adressiert, welche u. a. eine Verteilung von Verarbeitungsschritten in Netzwerken vorsehen.

⁴⁸³ Dies umfasst die Veröffentlichungen von Joshi (2020), S. 127 ff.; Döbel et al. (2018), S. 55 ff.; Jordan, Mitchell (2015), S. 259 f.

Bereich	Trend	Beschreibung	Potenzielle Auswirkung	Reifegrad
	Deep, Unsupervised, Reinforcement Learning	Weiterentwicklung der Lernverfahren	Höhere Genauigkeit, auch bei sehr komplexen Problemen	Hoch
	Explainable Artificial Intelligence	Selbsterklärungsfähigkeit der ML-Modelle	Höhere Interpretierbarkeit	Mittel
Lernverfahren	Generative Adversarial Networks	Generierung künstlicher Ergebnisse	Datenerweiterung; höhere Genauigkeit und Sicherheit	Gering
	Transfer Learning	Wiederverwendung von Wissen	Höhere Genauigkeit, auch bei kleinen Datenmengen	Gering
	Automated Machine Learning	Automatisierung des Entwicklungsprozesses	Geringerer Entwicklungsaufwand	Gering
Andere Technologien	Grey-Box-Modelle	Verbindung von manuellem und automatischem Wissenserverwerb	Höhere Genauigkeit und Recheneffizienz	Mittel
	Distributed Machine Learning	Verteilung von Verarbeitungsschritten auf mehrere technische Instanzen	Höhere Recheneffizienz, auch bei großen Datenmengen	Hoch
	Federated Machine Learning	Verteilung von Teilproblemen auf mehrere Akteure	Höherer Datenschutz	Mittel
	Quantum Machine Learning	Nutzung von Techniken der Quantenmechanik für Lernprozess	Höhere Recheneffizienz, auch bei großen Datenmengen	Gering

Tabelle 11: Forschungstrends zu ML mit Auswirkungen auf das Untersuchungsfeld

Ein zentraler Forschungsbereich im Kontext von ML bildet die Entwicklung tiefer NN, d. h. das **Deep Learning** (siehe Kapitel 2.4.3.1), welches maßgeblich für die mediale Aufmerksamkeit von ML in den letzten Jahren verantwortlich ist und auch zukünftig weitere Verbesserungen erwarten lässt.⁴⁸⁴ Neben der Nutzung für Lernaufgaben des Supervised Learning können tiefe NN insbesondere für hochdimensionale Problemstellungen mit Millionen von Parametern im Rahmen des bisher unterrepräsentierten **Unsupervised Learning** eingesetzt werden, z. B. bei der Verarbeitung von Sprach- und Bilddaten.⁴⁸⁵ Ein weiterer zukunftsreicher Bereich stellt das **Reinforcement Learning** dar, welches ein hohes Potenzial für die Lösung von komplexen betrieblichen Problemen aufweist – ohne dass größere Hintergrundinformationen in Form von historischen Daten benötigt werden.⁴⁸⁶ Zusätzlich wird auch eine Kombination von USL und RL als bedeutende Entwicklung angesehen.⁴⁸⁷

Ein übergreifender Forschungstrend von ML, der aufgrund seiner Bedeutung auch als **dritte Welle von KI** bezeichnet wird, befasst sich mit der Überwindung des Black-Box-Charakters

⁴⁸⁴ Vgl. LeCun et al. (2015), S. 442

⁴⁸⁵ Vgl. Jordan, Mitchell (2015), S. 257 f.

⁴⁸⁶ Ein prominentes Beispiel stellt das in Kapitel 2.4.1.4 beschriebene und mittels RL-Verfahren trainierte System „AlphaGo Zero“ dar, welches die Ergebnisse seiner Vorgängerversionen, die ausschließlich NN verwenden, deutlich überbietet. Vgl. Silver et al. (2017), S. 354 ff.

⁴⁸⁷ Vgl. LeCun et al. (2015), S. 442

von ML durch die Realisierung interpretierbarer Lernverfahren bzw. darauf basierender Modelle, anhand derer die jeweiligen Nutzer die Ergebnisse und Lösungswege kontextbezogen und auf verschiedenen Detaillierungsebenen nachvollziehen können.⁴⁸⁸ Eine systemseitige Interpretierbarkeit wird als gegeben erachtet, wenn – analog zu einem White-Box-Modell – die Nutzer beschreiben können, wie sich die Ergebnisse der Systeme durch weitere Eingaben verhalten.⁴⁸⁹ Die damit verbundenen Forschungsaktivitäten werden unter dem Begriff der erklärbaren KI bzw. **Explainable Artificial Intelligence (XAI)** subsumiert und sind aufgrund ihrer Bedeutung für viele Anwendungsbereiche in die US-amerikanische Roadmap für die KI-Forschung der nächsten 20 Jahre aufgenommen.⁴⁹⁰ Hierzu gehören u. a. Ansätze zur verständlichen Nachbildung der realisierten Modelle, die Entwicklung interpretierbarer Lernverfahren sowie die Bereitstellung zusätzlicher Informationen für die Nutzer, z. B. in Form der jeweils relevanten Features.⁴⁹¹

Als weiterer Forschungstrend gilt das **Informed Machine Learning (IML)**, welches ebenfalls dem XAI zuzuordnen ist und eine gezielte Integration von menschlichem Wissen in ML-Anwendungen vorsieht.⁴⁹² Neben dem automatisch auf Basis von Daten erworbenen Wissen werden den entsprechenden Systemen dabei zusätzlich Informationen auf Grundlage von menschlichen Erfahrungen bereitgestellt, sodass in diesem Zusammenhang auch von **Grey-Box-Modellen** bzw. hybriden kognitiven Systemen gesprochen wird.⁴⁹³ Bei dem menschlichen „Vorwissen“ kann es sich u. a. um naturwissenschaftliche Zusammenhänge, linguistische und semantische Regeln sowie um domänenspezifisches Expertenwissen und Simulationsergebnisse handeln, welches mittels Formeln, logischen Regeln, Wissensgraphen oder Wahrscheinlichkeitsverteilungen repräsentiert wird.⁴⁹⁴ Über diese Batch-Bereitstellung hinaus ist auch eine kontinuierliche Integration möglich, indem die systemseitigen Ergebnisse durch die Nutzer bewertet und an die Systeme rückgekoppelt werden, sodass sie zu einer Beeinflussung des zukünftigen Lernprozesses führen.⁴⁹⁵ Insgesamt wird mit dem IML eine Verbesserung der Genauigkeit und Recheneffizienz von ML-Anwendungen angestrebt, indem z. B. reale Phänomene, welche von einer hohen Individualität und eingeschränkten Datenverfügbarkeit geprägt sind, adäquat berücksichtigt werden können.

Der durch *Goodfellow et al. (2014)* begründete Ansatz der **Generative Adversarial Networks (GAN)** stellt einen weiteren wichtigen Forschungstrend dar, welcher die Erzeugung künstlicher Ergebnisse für reale Phänomene ermöglicht – wobei es sich dabei nicht nur um eine graduelle Veränderung handeln kann, sondern auch um die Generierung gänzlich neuer Gestaltungsformen. Der GAN-Ansatz sieht eine Kombination von zwei unterschiedlich konfigurierten NN

⁴⁸⁸ Vgl. Fouse et al. (2020), S. 6

⁴⁸⁹ Vgl. Gil, Selman (2019), S. 71

⁴⁹⁰ Vgl. Gil, Selman (2019), S. 56

⁴⁹¹ Vgl. Döbel et al. (2018), S. 82 f.

⁴⁹² Vgl. Rueden et al. (2019), S. 1

⁴⁹³ Vgl. Wahlster, Winterhalter (2020), S. 12; Döbel et al. (2018), S. 71 f.

⁴⁹⁴ Vgl. Rueden et al. (2019), S. 6 f.

⁴⁹⁵ Vgl. Rueden et al. (2019), S. 14

vor, welche gewissermaßen in einem Wettbewerb agieren.⁴⁹⁶ Während das eine NN als generatives Modell fungiert, indem es die Struktur und Verteilung von Daten mittels USL lernt, wird das andere NN als diskriminatives Modell eingesetzt, welches anhand von weiteren, bereits gelabelten Datensätzen prüft, ob die Ergebnisse des ersten NN zu einer gewünschten Klasse gehören. Die Ergebnisse dieser Prüfung werden anschließend an das erste NN zurückgegeben und führen zur Anpassung von dessen Lernprozess. Das Lernziel besteht darin, solche Ergebnisse zu generieren, die das zweite NN nicht von echten Daten unterscheiden kann. GAN werden in der Praxis bereits zur Generierung künstlicher Gesichter, Musik und Kunst eingesetzt, wobei auch eine missbräuchliche Nutzung in Form von sog. Deep Fakes zu beobachten ist. Gleichzeitig kann dieser Ansatz auch zur Verbesserung von ML-Anwendungen verwendet werden. Durch eine bewusste Vorgabe von falschen Ergebnissen (Adversarial Examples) lässt sich zum einen die Robustheit von Modellen gegenüber Manipulationen erhöhen.⁴⁹⁷ Zum anderen wird auch eine Erweiterung bestehender Datensätze (Data Augmentation) durch die Generierung künstlicher Daten ermöglicht.⁴⁹⁸ Aufgrund der zentralen Bedeutung von GAN sind hierzu substantielle Verbesserungen zu erwarten, die auch den aktuellen Herausforderungen eines bisher sehr ressourcenaufwändigen Lernprozesses begegnen.⁴⁹⁹

Aus der Restriktion vieler Problemstellungen in Hinblick auf eine eingeschränkte Datenverfügbarkeit hat sich der Forschungsbereich des **Transfer Learning (TL)** entwickelt, welcher auch teilweise mit den Aktivitäten des Domain Adaptation gleichgesetzt wird.⁵⁰⁰ Bei diesem Ansatz wird ein bestehendes ML-Modell, welches für eine spezifische Problemstellung – zumeist unter Nutzung von tiefen NN – entwickelt wurde, zur Lösung einer anderen verwandten Problemstellung genutzt, für die jedoch deutlich weniger Daten vorliegen.⁵⁰¹ Das Ziel besteht darin, dass das jeweilige NN nicht alle Zusammenhänge der neuen Problemstellungen lernen muss, sondern das vorab erworbene Wissen lediglich anpasst, z. B. durch Veränderung der Gewichte zwischen den Neuronen, indem es Ähnlichkeiten zwischen beiden Aufgabentypen erkennt. Zukünftig soll dadurch die Nutzung von ML für unbekannte Anwendungsfälle anhand von sehr wenigen („One-shot-Learning“) bzw. gar keinen Trainingsfällen („Zero-shot-Learning“) ermöglicht werden.⁵⁰²

Auch für die effiziente Nutzung von ML für sehr große Datenmengen, dem sog. **Large-Scale Machine Learning**, lassen sich mehrere Forschungsaktivitäten feststellen.⁵⁰³ Ein bedeutender Ansatz stellt das verteilte Lernen bzw. **Distributed Machine Learning (DML)** dar, bei dem die Rechenleistung der bestehenden lokalen IT-Infrastruktur gebündelt wird.⁵⁰⁴ Anders als übli-

⁴⁹⁶ Vgl. hierzu und zu diesem Abschnitt Goodfellow et al. (2014), S. 1 ff.

⁴⁹⁷ Vgl. Döbel et al. (2018), S. 52, 89

⁴⁹⁸ Vgl. Ruder (2017), S. 3

⁴⁹⁹ Vgl. Tanaka, Aranha (2019), S. 4

⁵⁰⁰ Vgl. Joshi (2020), S. 127

⁵⁰¹ Vgl. hierzu und zu diesem Abschnitt Kaiser et al. (2017), S. 1 ff.

⁵⁰² Vgl. Döbel et al. (2018), S. 61

⁵⁰³ Vgl. Bottou (2010), S. 177

⁵⁰⁴ Vgl. Xing et al. (2015), S. 1

cherweise wird dazu der Lernprozess nicht zentral auf einem einzelnen lokalen Rechner (Knoten) ausgeführt, sondern verteilt in einem Verbund von mehreren Recheneinheiten (Cluster) – wobei ein Cluster aus vielen tausend Knoten bestehen kann.⁵⁰⁵ Die Knoten übernehmen dabei einzelne Teilaufgaben des gesamten Lernprozesses und übermitteln die diesbezüglichen Ergebnisse und Aktualisierungen an eine zentrale Instanz (Server), auf der die kontinuierliche Erstellung und Verwaltung eines globalen ML-Modells erfolgt.⁵⁰⁶ Durch die Parallelisierung der Berechnungen sowie die Beschränkung des Datenaustauschs zwischen den Knoten können hochdimensionale Problemstellungen gelöst und gleichzeitig die Rechenzeiten substantiell verkürzt werden. Relevante Forschungsaktivitäten zum DML beziehen sich u. a. auf die Verbesserung der Kommunikationsprotokolle und die Entwicklung von Lernverfahren, welche eine parallele Verarbeitung ermöglichen.⁵⁰⁷

Ein Forschungstrend mit Schnittstellen zum DML stellt das föderalisierte Lernen bzw. **Federated Machine Learning (FML)** dar, welches ebenfalls eine Aufteilung von Verarbeitungsschritten eines Gesamtproblems auf mehrere lokale Systeme und eine Übersendung der Ergebnisse an einen globalen Server vorsieht. Anders als beim DML steht dabei jedoch nicht die Verbesserung der Rechenleistung im Fokus, sondern vielmehr die Sicherstellung von Datenschutzerfordernissen.⁵⁰⁸ Dafür greifen die beteiligten Recheneinheiten beim FML nur auf bestimmte Ausschnitte des Gesamtdatensatzes zu. Auch die zentrale Instanz erhält lediglich die Teilergebnisse der Knoten – nicht aber die Rohdaten. Sie führt diese zu einem globalen Modell zusammen und sendet die Ergebnisse an die Knoten, welche auf dieser Grundlage ihre Modelle automatisiert anpassen.⁵⁰⁹ Durch diesen dezentralen Lernprozess können mehrere Akteure an verschiedenen Orten in die Lösung eines Problems eingebunden werden, ohne dass lokale bzw. sensible Daten ausgetauscht werden müssen.⁵¹⁰ Aktuelle Forschungsaktivitäten des FML umfassen u. a. die Entwicklung von Ansätzen für den Umgang mit den heterogenen und teils geringen Datenmengen der einzelnen Knoten, wozu auch das o. g. Transfer Learning genutzt wird.⁵¹¹ Für den sicheren Datenaustausch zwischen den einzelnen Akteuren wird zudem auf die Blockchain-Technologie zurückgegriffen, was zu der Begriffsbezeichnung des **Blockchained Federated Learning** führt.⁵¹²

Mit dem **Quantum Machine Learning (QML)** besteht ein weiterer sehr bedeutender, jedoch bisher noch weniger ausgereifter Forschungsbereich, der Aktivitäten zur Nutzung von Techniken aus der Quantenmechanik für die Entwicklung von ML-Anwendungen umfasst. Hierzu gehört der Einsatz von Quantencomputern bzw. -prozessoren, d. h. sog. Quantum Processing

⁵⁰⁵ Vgl. Jordan, Mitchell (2015), S. 259

⁵⁰⁶ Vgl. Xing et al. (2015), S. 17 ff.

⁵⁰⁷ Vgl. Jordan, Mitchell (2015), S. 259

⁵⁰⁸ Vgl. Yang et al. (2019), S. 3

⁵⁰⁹ Vgl. Konečný et al. (2016), S. 1 f.

⁵¹⁰ Vgl. Yang et al. (2019), S. 15

⁵¹¹ Vgl. Yang et al. (2019), S. 7

⁵¹² Vgl. Kim et al. (2018), S. 1

Unit (QPU), sowie die Entwicklung von dafür geeigneten Lernverfahren.⁵¹³ Während konventionelle Rechner Bits mit den Zuständen Null oder Eins abspeichern und nacheinander verarbeiten, nutzen QPU die sog. Quantenbits (Qubits), welche mittels einer Überlagerung (Superposition) und Verschränkung (Entanglement) gleichzeitig diese beiden Zustände sowie auch alle dazwischenliegenden annehmen können.⁵¹⁴ Hierdurch ist es möglich, deutlich mehr Daten in der gleichen Zeit parallel zu verarbeiten, sodass auch sehr rechenintensive Probleme in kurzen Zeit gelöst werden können.⁵¹⁵

Weitere Forschungsaktivitäten, die unter dem Begriff des **Automated Machine Learning (AutoML)** subsumiert werden, zielen auf die Automatisierung des Entwicklungsprozesses von ML-Modellen ab.⁵¹⁶ In Ergänzung zur automatisierten Anpassung von Modellen beim Re-Training durch die Realisierung einer ML-Pipeline (siehe Kapitel 4.1.1) sollen dabei auch die manuell geprägten Schritte der initialen Modellentwicklung systemseitig ausgeführt werden, d. h. die Datenaufbereitung, das Feature Engineering, die Generierung geeigneter Modelle unter Berücksichtigung mehrerer Lernverfahren und Parametrisierungen sowie die Validierung.⁵¹⁷ Neben der Beschleunigung der Entwicklung wird im AutoML-Ansatz auch ein hohes Potenzial zur Generierung optimaler und innovativer Lösungswege gesehen, da die ausführenden Systeme den Lösungsraum von möglichen Modellkonfigurationen effizienter und systematischer durchsuchen können. Derzeitige Forschungsaktivitäten in diesem Bereich befassen sich mit Möglichkeiten zur Kompensation des menschlichen Domänenwissens, welches u. a. beim Feature Engineering benötigt wird.⁵¹⁸

4.4.2 Umfeldentwicklungen

Zusätzlich zu den ML-seitigen Forschungstätigkeiten lassen sich weitere Entwicklungen feststellen, welche potenziell einen Einfluss auf den Einsatz von ML-Anwendungen im Logistikmanagement ausüben. Deren Ermittlung erfolgte sowohl unter Berücksichtigung mehrerer Trendstudien mit Relevanz für das Untersuchungsfeld⁵¹⁹ als auch durch Befragung von Vertretern aus der logistischen Praxis im Rahmen der Interviews. Die hieraus resultierenden Ergebnisse wurden auf Grundlage einer STEP-Analyse systematisiert, d. h. in Bezug auf soziokulturelle (S), technische (T), wirtschaftliche (E) sowie politische und rechtliche (P) Umfeldentwicklungen. Insgesamt lassen sich **mehrere förderliche, aber auch einzelne hemmende Faktoren** beobachten, welche nachfolgend mit ihren Implikationen für das Untersuchungsfeld beschrieben sind. Vorab findet sich dazu in Tabelle 12 eine Zusammenfassung.

⁵¹³ Vgl. Bauckhage et al. (2020), S. 27

⁵¹⁴ Vgl. Schuld, Petruccione (2018), S. 89 ff.

⁵¹⁵ Vgl. Biamonte et al. (2017), S. 196; Döbel et al. (2018), S. 61

⁵¹⁶ Vgl. He et al. (2019), S. 1

⁵¹⁷ Vgl. Joshi (2020), S. 132

⁵¹⁸ Vgl. He et al. (2019), S. 23 ff.

⁵¹⁹ Dies umfasst die Veröffentlichungen von Straube (2019), S. 35 ff.; Kersten et al. (2017), S. 19 ff.; Handfield et al. (2013), S. 14 ff.

Bereich	Trend	Beschreibung	Potenzielle Auswirkung
E	Volatilität	Höhere zeitliche und mengenmäßige Schwankungen der Kundennachfrage	Schnelle, flexible Entscheidungen notwendig
E	Störanfälligkeit	Zunahme von Störungen in Lieferketten	Antizipation von Ereignissen benötigt
E	Kostendruck	Stärkere Preisorientierung der Kunden und Wettbewerbsintensität	Effiziente Gestaltung der Logistiksysteme notwendig
E	Transparenz	Höhere Transparenz über Lieferketten für Kunden und Gesetzgeber	„Wertschöpfende“ Informationen und digitale Services benötigt
P	Regulierung	Zunahme von rechtlichen und ethischen Anforderungen an Einsatz von ML	Realisierung sicherer und vertrauenswürdiger Systeme
S	Demografischer Wandel	Zunahme von Digital Natives gegenüber Digital Immigrants	Höhere Akzeptanz gegenüber Technologieeinsatz
S	Personalmangel	Begrenzte Verfügbarkeit von ML-Fachkräften	Fehlendes Wissen bzw. hohe Kosten für Rekrutierung
T	Digitalisierung	Ausstattung von Objekten mit Sensorik und Nutzung digitaler Endgeräte	Anstieg der Datenmenge
T	Plattformökonomie	Zunahme der IT-seitigen Vernetzung von Unternehmen	Erleichterter Zugang zu externen Daten
T	5G	Erhöhung der Netzabdeckung	Kürzere Latenz bei Kommunikation
T	Prozessoren	Weiterentwicklung bestehender und neuer Prozessortechnik	Höhere Rechenleistung
T	Edge Computing	Verbesserte Ansätze zur dezentralen Nutzung bestehender IT-Infrastruktur	Höhere Rechenleistung
T	Cloud Computing	Erweiterung des externen Angebots zu IaaS und MLaaS	Höhere Rechenleistung, Speicherkapazität und Zugriff auf ML-Services

Tabelle 12: Umfeldentwicklungen mit Auswirkungen auf das Untersuchungsfeld

Aufgrund von Veränderungen im Bestellverhalten sehen sich Unternehmen zunehmend mit höheren Nachfrageschwankungen ihrer Kunden konfrontiert. Zusätzlich lässt sich infolge der globalen Ausrichtung von Wertschöpfungsstrukturen eine steigende Störanfälligkeit von Lieferketten beobachten, welche seit der COVID-19-Pandemie eine weitere Verstärkung erfahren hat. Der Aufbau von Beständen oder anderen ressourcenseitigen Risikopuffern zur Begegnung dieser Herausforderungen kommt dabei häufig infolge des hohen Kostendrucks, welcher im Zusammenhang mit einer geringen Zahlungsbereitschaft der Kunden für logistischer Dienstleistungen steht, nicht infrage. Vielmehr bedarf es einer Realisierung **effizienter, zuverlässiger und gleichzeitig anpassungsfähiger Logistiksysteme**. Entsprechend der damit verbundenen planerischen Komplexität für die Entscheidungsträger wird von einem steigenden Bedarf der Unternehmen an geeigneten IT-Systemen zur Unterstützung und Ausführung von logistischen Entscheidungsprozessen ausgegangen, was als förderlich für den zukünftigen Einsatz von ML-Anwendungen angesehen wird.

Gleichzeitig lassen sich auch steigende Anforderungen der Kunden und des Gesetzgebers an die Transparenz von Lieferketten beobachten, welche sich – über die Meldungen zum aktuel-

len und historischen Status im Sinne des Tracking-and-Tracing hinaus – auf **Hintergrundinformationen und zukünftige Entwicklungen** der jeweiligen Aufträge und der damit verbundenen Parameter beziehen. Hierzu zählt auch das im Jahre 2021 verabschiedete LkSG zur Detektion von Menschenrechtsverletzungen entlang der Lieferkette. Neben dem zuvor aufgeführten Einsatz für interne Optimierungen werden daher auch Systeme zur Überwachung der Logistikprozesse benötigt, deren Informationen als **digitale Services** an externe Stakeholder bereitgestellt werden können. Auch diese Entwicklung wird als unterstützender Faktor für zukünftige Adoptionsentscheidungen zu ML-Anwendungen gewertet.

Regulatorische Anforderungen und damit verbundene Entwicklungen können den Einsatz von ML im Falle einer fehlenden Konformität allerdings auch negativ beeinflussen. Aus heutiger Sicht sind v. a. **Regeln zur Datensicherheit und zum Datenschutz** zu berücksichtigen. Hierzu zählt in Deutschland das Bundesdatenschutzgesetz (BDSG) sowie die europäische DSGVO, welche seit 2018 angewendet werden muss und u. a. Vorgaben zur Nachvollziehbarkeit der Verarbeitung und der Verwendung von personenbezogenen Daten enthält. Ausgehend von dem heutigen Empfehlungscharakter ist zukünftig auch von verbindlichen Regeln zur **Einhaltung ethischer Standards** durch ML-Anwendungen auszugehen. Diese sehen eine Realisierung vertrauenswürdiger Systeme vor, welche sich u. a. durch eine Diskriminierungsfreiheit (sog. Fairness) auszeichnen.⁵²⁰ Hierdurch soll eine Benachteiligung von Menschen aufgrund personenbezogener Merkmale verhindert werden, wie es in der Vergangenheit bereits in der Praxis zu beobachten war, z. B. im Rahmen der automatischen Bewertung von Bewerbungsunterlagen⁵²¹. Die eingesetzten Anwendungen müssen dabei auch externen Auditierungen standhalten, wie sie bereits durch den Gesetzgeber avisiert sind.⁵²²

Eine bedeutende Entwicklung für den Einsatz von ML-Anwendungen stellt der kontinuierliche **Anstieg der Datenmenge** dar, welcher auf die zunehmende Digitalisierung aller Lebensbereiche zurückzuführen ist.⁵²³ Im betrieblichen Kontext betrifft dies v. a. einen vermehrten Einsatz von IoT-Geräten (Internet of Things), d. h. eine Ausstattung von Objekten mit Sensorik, wie z. B. RFID (Radio-Frequency Identification). Dies führt auch in der Logistik zu einer Generierung von zusätzlichen Daten, die potenziell für ML-Anwendungen genutzt werden können. Durch eine stärkere Verbreitung des neuen Mobilfunkstandards 5G können die entsprechenden Daten zudem **mit einer geringen Latenz ausgetauscht** werden, was insbesondere für die Realisierung autonomer Systeme von hoher Bedeutung ist. Zusätzlich wird auch von verbesserten Zugangsbedingungen der Unternehmen zu externen Daten ausgegangen. Dies steht im Zusammenhang mit der **fortschreitenden Vernetzung** von Unternehmen mit Lieferanten und Kunden, aber auch mit Wettbewerbern. Als branchenweit bedeutende Stellvertreter

⁵²⁰ Vgl. Europäische Kommission (2019), S. 11 f.

⁵²¹ Vgl. Dastin (2018)

⁵²² Vgl. Deutsche Bundesregierung (2018), S. 27, 40

⁵²³ Im Vergleich zum Jahre 2018 wird sich die weltweite Datenmenge bis 2025 von 33 auf voraussichtlich 175 Zettabyte mehr als verfünffachen. Vgl. Tenzer (2020)

der Plattformökonomie sind die Volkswagen Industrial Cloud, die Open Manufacturing Plattform von Microsoft und BMW sowie das SAP Business Network und das europäische Projekt GAIA-X zu nennen.

Auch in Bezug auf die verfügbare Rechenleistung, welche ebenfalls eine bedeutende Grundlage für den Betrieb von ML-Anwendungen darstellt, wurden in der Vergangenheit bedeutende Verbesserungen erzielt, die sich auch in Zukunft – mit einer zusätzlichen Kostendegression – fortsetzen werden. Dies betrifft Fortschritte bei neuen Prozessortechniken in Form der in Kapitel 4.4.1 genannten QPU, aber auch Weiterentwicklungen von bereits für ML etablierte Prozessorarten in Form der TPU (Tensor Processing Unit) und der GPU (Graphics Processing Unit). Zusätzlich zu den Prozessoren lassen sich auch zwei weitere Entwicklungen feststellen, welche die Voraussetzungen der Unternehmen für einen **Zugriff auf höhere Rechenleistungen** verbessern. Dies betrifft zum einen verbesserte Ansätze zur Nutzung bestehender Infrastruktur in Form der Dezentralisierung der Datenverarbeitung auf mehrere lokale Recheneinheiten (Edge Computing). Mit dem DML und FML in Kapitel 4.4.1 wurden hierfür bereits zwei bedeutende Forschungstrends benannt. Zum anderen verbessern sich ebenfalls die Möglichkeiten für die Unternehmen zur Nutzung externer Rechen- und Speicherkapazitäten in Form von IaaS (Cloud Computing), welche zudem im Rahmen der Vertragsgestaltung flexibel angepasst werden können (Pay-per-Use). Zusätzlich lässt sich ein stetig steigendes Angebot an Leistungen zur automatisierten Unterstützung des Entwicklungsprozesses von ML-Anwendungen im Sinne des beschriebenen AutoML-Ansatzes beobachten. Die als **Machine-Learning-as-a-Service (MLaaS)** bezeichneten Dienstleistungen werden mittels API bereitgestellt und umfassen z. B. Aktivitäten der Datenaufbereitung und der Modellentwicklung. Zu bedeutenden Anbietern in diesem Bereich gehören die „Hyperscaler“ Amazon Web Services (AWS), Microsoft Azure und die Google Cloud Platform sowie die IBM Cloud und SAP HANA.⁵²⁴

Zusätzlich lassen sich auch hinsichtlich des sozial-kulturellen Umfeldes zwei bedeutende Entwicklungen für das Untersuchungsfeld feststellen. Dazu gehört der demografische Wandel, welcher zu einer Vergrößerung der Gruppe von Digital Natives gegenüber den sog. Digital Immigrants führt. Da erstere eine vergleichsweise ausgeprägte Technikaffinität und -kompetenz aufweisen, wird dieser Generationswechsel in den Unternehmen auch mit einer langfristigen **höheren Akzeptanz für den Einsatz von IT-Systemen** zur Unterstützung oder Ausführung von Entscheidungsprozessen assoziiert. Die zweite Entwicklung betrifft die Möglichkeiten zum Rückgriff auf Fachkräfte für die Umsetzung von ML-Anwendungen, wozu sowohl Data Engineers (Dateningenieure) zur Aufbereitung und Analyse von Daten als auch Data Scientists (Datenwissenschaftler) zur Entwicklung der Modelle gehören. Hier zeigt sich, dass in Deutschland und in vielen weiteren Ländern aktuell und zukünftig **weniger Fachkräfte am Markt zur Verfügung** stehen, als insgesamt benötigt werden⁵²⁵.

⁵²⁴ Eine Analyse der unterschiedlichen Services findet sich in Weber (2020), S. 91 ff.

⁵²⁵ Vgl. Deutscher Bundestag (2020), S. 4

5 Anwendungsmöglichkeiten

In diesem Kapitel werden die Anwendungsmöglichkeiten von ML im Logistikmanagement identifiziert. Auf Grundlage bestehender Anwendungen wird hierfür eine Typologie entwickelt, welche durch eine geeignete Reduzierung der prozessualen und technischen Komplexität des Untersuchungsfeldes das gegenwärtige Anwendungsspektrum repräsentiert und gleichzeitig Aussagen zu zukünftigen Erweiterungen zulässt. Unter zusätzlicher Berücksichtigung von bereits in der Praxis umgesetzten Anwendungen werden zudem die potenziellen Auswirkungen des Technologieeinsatzes für logistische Entscheidungsprozesse herausgearbeitet. Mittels dieser Untersuchungen soll die dritte sekundäre Forschungsfrage beantwortet werden:

Wie kann das Anwendungsspektrum von ML im Logistikmanagement systematisiert und bewertet werden? Welche Implikationen ergeben sich für die Ausführung von logistischen Entscheidungsprozessen?

Zu Beginn des Kapitels wird das gewählte **Forschungsdesign** konkretisiert (Kapitel 5.1). Unter Rückgriff auf das zugrundeliegende Datenmaterial erfolgt im nächsten Schritt eine **Charakterisierung des Anwendungsspektrums** in Form der gebildeten Typen (Kapitel 5.2). Diese Informationen dienen einer anschließenden **Theoriebildung**, welche sich zum einen auf die Abdeckung der Aktivitäten von logistischen Entscheidungsprozessen, auf Zusammenhänge zwischen prozessualen und technischen Eigenschaften, auf potenzielle Erweiterungen und auf die praktische Bedeutung des Anwendungsspektrums bezieht (Kapitel 5.3). Zum anderen umfasst dies auch die Ermittlung verschiedener **Auswirkungen**, die aus dem Einsatz von ML-Anwendungen hervorgehen (Kapitel 5.4). In Sinne einer Synthese der gewonnenen Erkenntnisse werden im letzten Schritt generelle Kriterien zur **Prüfung der Eignung von ML** für Anwendungsfälle im Logistikmanagement abgeleitet (Kapitel 5.5).

5.1 Forschungsdesign

Die Untersuchungen in diesem Kapitel folgen den Erkenntnissen des TPC-Modells. Hierzu wurde eine für das vorliegende Forschungsziel zweckmäßige Verkürzung um die Nutzungsdimension vorgenommen (siehe Kapitel 2.1.3.4).⁵²⁶ Die damit verbundene Einnahme einer rein **prozessual-technischen Betrachtungsperspektive** sieht für die jeweiligen Systeme eine Prüfung der realisierbaren technischen Funktionalitäten und der adressierten Aufgaben vor, wobei deren geeignete Kombinationen das Anwendungsspektrum repräsentieren (siehe Abbildung 45). Die Eignung bemisst sich dabei anhand der resultierenden Auswirkungen, welche im TPC-Modell in Form einer Leistungsdimension berücksichtigt sind und die Zielsetzung für den Technologieeinsatz darstellen. Anstelle einer quantitativen Bewertung des Zusammenwir-

⁵²⁶ Die an dieser Stelle unberücksichtigte Perspektive der Nutzer bzw. der Adoptionssubjekte im Allgemeinen wird durch die Untersuchungen in Kapitel 6 sichergestellt.

kens dieser drei Dimensionen, wie es bei der Prüfung *spezifischer* Anwendungsfälle im Rahmen des TPC-Modells erfolgt, wird bei der vorliegenden anwendungsfallübergreifenden Betrachtung die **Gesamtheit möglicher Ausprägungen** für das Untersuchungsfeld ermittelt.




Abbildung 45: Untersuchungsdimensionen zu Anwendungsmöglichkeiten von ML⁵²⁷

Die benötigten Informationen für die Funktionalitäten und Aufgaben von ML-Anwendungen im Logistikmanagement beziehen sich auf das prozessuale und technische Subsystem des Untersuchungsfeldes gemäß der in Kapitel 2.5 vorgenommenen systemtechnischen Modellierung. Im Hinblick auf den angestrebten Einsatz der Anwendungen als Entscheidungstechniken handelt es sich hierbei um die mittels ML realisierbaren **Problemlösungsfähigkeiten** sowie um **logistische Entscheidungsprozesse**, welche durch ML unterstützt bzw. ausgeführt werden können. Die für das Anwendungsspektrum relevanten Auswirkungen umfassen zuvorderst die direkten Veränderungen der Ausführung von Planungs-, Steuerungs- und Überwachungsaktivitäten, welche im Folgenden als ML-spezifische **Wirkungsdimensionen** bezeichnet werden. Weiterhin handelt es sich um betriebswirtschaftlich relevante **Nutzenpotenziale**, welche durch die „Operationalisierung“ dieser Dimensionen in Form der Nutzung der Anwendungen für die Lösung spezifischer Problemstellungen entstehen. Gleichzeitig können auch negative Auswirkungen in Form von **Risiken** eintreten, welche daher ebenfalls in die Untersuchung miteinbezogen werden. Die Erkenntnisse zu den Auswirkungen in diesem Kapitel basieren auf der durchgeführten **Online-Befragung** und den **Experteninterviews**, einschließlich der im Kapitel 4.3 vorgenommenen Fallstudienforschung. Für die Ermittlung des Anwendungsspektrums wurde dagegen auf Sekundärdaten zurückgegriffen und eine Typenbildung in Form einer Clusteranalyse durchgeführt (siehe Kapitel 3.2). Um hierbei gleichzeitig Aussagen zur prozessualen und technischen Dimension des Anwendungsspektrums sowie zu deren Zusammenhängen und potenziellen Erweiterungsmöglichkeiten treffen zu können, wurde eine **separate Typenbildung** für die Problemlösungsfähigkeiten von ML-Anwendungen und für die adressierten logistischen Entscheidungsprozesse vorgenommen, deren Ausprägungen anschließend wieder kombiniert werden konnten (siehe Abbildung 46).

⁵²⁷ Eigene Darstellung

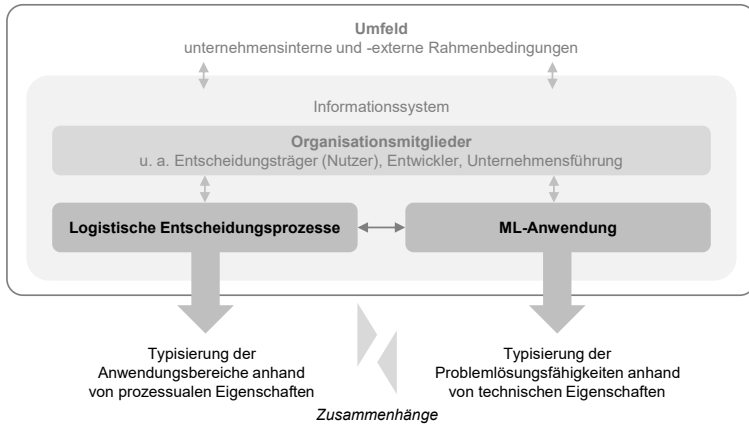



Abbildung 46: Bildung von Typen für Probleme und Problemlösungsfähigkeit von ML⁵²⁸


Bei den genutzten Daten zur Bildung beider Typenarten handelt es sich um Informationen zu Eigenschaften von **115 bestehenden ML-Anwendungen**, welche im Rahmen der systematischen Literaturanalyse für den Zeitraum von 2012 bis 2020 aus der Forschung identifiziert wurden. Die Extraktion dieser Informationen, welche im Folgenden auch als „prozessuale“ und „technische“ Eigenschaften bezeichnet werden, erfolgte unter Nutzung geeigneter Merkmale.⁵²⁹ Im Falle der Problemlösungsfähigkeit der ML-Anwendungen umfasst dies Merkmale zu den ML-Modellen in Form der genutzten Lernverfahren und -aufgaben, zum systemseitigen In- und Output sowie zur übergeordneten datenanalytischen Zielstellung. Für die sechs relevanten Merkmale wurden insgesamt **22 Ausprägungen** identifiziert. Die Merkmale zum logistischen Anwendungsbereich beziehen sich auf die logistische Aufgabenart, auf unternehmensinterne und/oder -externe Schnittstellen der adressierten Entscheidungsprozesse, auf das Bezugsobjekt, auf die bisherige Art der Entscheidungsausführung sowie auf die logistischen bzw. betrieblichen Zielsetzungen. Insgesamt lagen für die sieben relevante Merkmale **32 Ausprägungen** vor. Für den finalen Merkmalsraum zur technischen und prozessualen Charakterisierung der ML-Anwendungen sind die Korrelationsmatrizen in Abbildung 47 dargestellt. Hohe positive Korrelationen über dem Grenzwert von $r = 0,9$ liegen bei diesen Merkmalen nicht mehr vor. Es sind lediglich vereinzelt starke negative Korrelationen festzustellen, aus denen sich jedoch keine nachteiligen Auswirkungen für den Gruppierungsvorgang ergaben, da es sich stets um die Ausprägungen *eines* Merkmals handelte.

⁵²⁸ Eigene Darstellung

⁵²⁹ Die verwendeten Merkmalen für beide Typenarten sind in Tabelle 34 im Anhang aufgeführt.

Abbildung 47: Korrelationsmatrizen für beide Merkmalsarten⁵³⁰

Die Merkmalsausprägungen bildeten die Eingangsvariablen für die Clusteranalyse, welche mittels eines entwickelten **Algorithmus auf Basis der Ward-Methode** umgesetzt wurde. Für den Betrachtungsbereich der Gruppierung wurde eine Untergrenze von vier und eine Obergrenze von acht Clustern vorgegeben. Anhand der Ausprägungen der Dunn-Indizes und der Dendrogramme für verschiedene Clusteranzahlen konnte im Rahmen einer iterativen Durchführung des Gruppierungsprozesses die optimale Konfiguration für beide Typenarten ermittelt werden. Im Falle der Problemlösungsfähigkeit von ML-Anwendungen lag die optimale Anzahl bei **fünf Typen**, da hier der DI erstmalig das Maximum innerhalb der festgelegten Grenzen erreichte (siehe Abbildung 48 links). Analog zu dieser Begründung stellten **sieben Typen** die optimale Anzahl für den logistischen Anwendungsbereich dar (siehe Abbildung 48 rechts).

Abbildung 48: Dunn-Indizes für die Clusteranzahl beider Subsysteme⁵³¹

⁵³⁰ Eigene Darstellung. Die Achsenbeschriftungen entsprechen den Nummerierungen der Merkmale.

⁵³¹ Eigene Darstellung

Für diese optimale Clusteranzahl beider Dimensionen sind in Abbildung 49 die jeweiligen Dendrogramme dargestellt, wobei die Schnittpunkte der vertikalen Linien mit der gestrichelten horizontalen Linie die finalen Cluster repräsentieren. Die vereinzelt auftretenden Lücken auf der X-Achse resultieren aus einer sehr geringen Distanz der Merkmalsausprägungen von einzelnen ML-Anwendungen, welche bei völliger Übereinstimmung auch Null betragen kann.




Abbildung 49: Dendrogramme für den Gruppierungsvorgang beider Subsysteme⁵³²

5.2 Charakterisierung der Anwendungstypen

In diesem Unterkapitel wird das Anwendungsspektrum von ML in Form der identifizierten Typen für die realisierbaren Problemlösungsfähigkeiten und die adressierten Entscheidungsprozesse charakterisiert. Dies erfolgt für beide Typenarten entlang einer einheitlichen Struktur und unter Nutzung des zugrundeliegenden Datenmaterials in Form der Merkmalsausprägungen, welche der Ableitung von **typeninternen und -übergreifenden Gemeinsamkeiten und Unterschieden** sowie von weiteren besonderen Eigenschaften dienen. Der Übergang zwischen den Typen ist hierbei oft fließend, da bestimmte Eigenschaften in mehreren Typen gleichzeitig vorhanden sind. An mehreren Stellen der Ausführungen wird ein Bezug zu individuellen ML-Anwendungen bzw. zu den korrespondierenden Veröffentlichungen hergestellt, wobei im Sinne der angestrebten Realtypen möglichst repräsentative Fälle verwendet werden.⁵³³

5.2.1 Problemlösungsfähigkeiten

Die fünf identifizierten Typen zur technischen Dimension von ML-Anwendungen repräsentieren deren Problemlösungsfähigkeiten für die Unterstützung bzw. Ausführung von logistischen Entscheidungsprozessen. Ausgehend von einer Zusammenfassung in Tabelle 13 werden die einzelnen Typen in den nachfolgenden Abschnitten charakterisiert. Die zwei Typen der Prognose werden dabei in diesen und den weiteren Ausführungen aufgrund hoher inhaltlicher Schnittmengen zusammen betrachtet.

⁵³² Eigene Darstellung

⁵³³ Eine Zuordnung der nachfolgend aufgeführten Veröffentlichungen zu den einzelnen Typen findet sich in Tabelle 35 im Anhang.

Merkmal	Identifikation	Analyse & Bewertung	Prognose	Optimierung
Problemlösungsfähigkeit	<p>Kontinuierliche Ermittlung von vorgefertigten Objekten und Zuständen</p> <p>Probleme mit vielen, teils sehr ähnlichen Eigenschaften und eiliger geringen Zeit zur Reaktion</p> <ul style="list-style-type: none"> - Bestimmung von Objekten und deren Zustand - Bestimmung von Prozess- und Maschinenzuständen, u. a., Störungen 	<p>Punktuelle Ermittlung von tieferliegenden Zusammenhängen</p> <p>Probleme mit einer hohen Anzahl an bestehenden Lösungsmöglichkeiten</p> <ul style="list-style-type: none"> - Segmentierung von Betrachtungsobjekten, z. B. Materialarten, Störungsszenarien - Bestimmung geeigneter Handlungsalternativen aus bestehenden Optionen, z. B. Lieferantenauswahl 	<p>Ermittlung von zukünftigen Parametern und Zuständen, inkl. unterschiedlicher Szenarien</p> <p>Probleme mit hoher Unsicherheit durch viele dynamische Variablen</p> <ul style="list-style-type: none"> - Bestimmung zukünftiger Parameterausprägungen, u. a. Materialbedarfe, Kapazitäten, Kosten, Prozesszeiten - Bestimmung zukünftiger Leistung und Qualität, u. a. von Prozessen, Maschinen, Akteuren - Bestimmung zukünftiger Ereignisse, z. B. Störungen 	<p>Ermittlung optimaler Parameter und Strategien</p> <p>Probleme mit vielen, teils dynamischen Variablen und konfliktären Zielsetzungen</p> <ul style="list-style-type: none"> - Zuordnung von Aufträgen zur Eigen- oder Fremdfertigung, zu Arbeitsstationen und zu Transporten, inkl. Gestaltung der Sequenz - Festlegung von Prozess- und Maschinenparametern - Harmonisierung verschiedener Planungsaktivitäten
Anwendungsfälle	<ul style="list-style-type: none"> - Supervised, Deep Learning - Tiefe NN, SVM - Klassifikation, Ausreißerkennung 	<ul style="list-style-type: none"> - Supervised, Deep Learning, Evolutionary Learning - u. a. KNN, SVM - Klassifikation, Clustering, Ranking, Wissensextraktion, Assoziationsanalyse 	<ul style="list-style-type: none"> - Supervised, Deep, Evolutionary Learning - Häufig KNN, aber auch weitere NN, GA, SVM; Entscheidungsbäume, Bayes - Regression, Klassifikation 	<ul style="list-style-type: none"> - Reinforcement, Evolutionary Learning - Q-Learning, TPA, GA - Optimierung, Erzeugung neuer Inhalte
ML-Modelle	<ul style="list-style-type: none"> - Permanente Bereitstellung des Outputs in Echtzeit - Verbindung mit Hardware zur Datengewinnung, u. a. Kamera, Sensorik, Smart Wearables (komplexe Daten) - Hoher Fokus auf Flexibilität der Modelle 	<ul style="list-style-type: none"> - Bedarfsbezogene Bereitstellung des Outputs - Zusätzliche Ausgabe von Hintergrundinformationen, wie Regeln, Feature Importance oder Wahrscheinlichkeiten 	<ul style="list-style-type: none"> - Punktuelle oder bedarfsbezogene Bereitstellung des Outputs in regelmäßigen Abständen - Für einige Probleme existiert bereits ein vergleichsweise hoher technischer Reifegrad 	<ul style="list-style-type: none"> - Punktuelle oder permanente Bereitstellung des Outputs - Entweder manuelle Ausführung oder Verbindung mit Ausführungssystemen zur Automation, u. a. MES
Weitere technische Eigenschaften				

Tabelle 13: Zusammenfassung der Typen für Problemlösungsfähigkeit

5.2.1.1 Identifikation

Die ML-Anwendungen des Clusters der Identifikation dienen einer präzisen Erkennung von Objekten und Zuständen im Rahmen einer permanenten Beobachtung der entsprechenden Prozesse. Es sollen hierbei möglichst in Echtzeit Informationen bereitgestellt werden, um die logistische Leistungserstellung frühzeitig und zielgerichtet beeinflussen zu können, z. B. in Form einer Erhöhung der Prozessqualität oder einer Prozessbeschleunigung.

Mehrere der Anwendungen werden zur Unterscheidung von verschiedenen Objektarten eingesetzt, z. B. von eingehenden Materialien im Wareneingang, aber auch zur Detektion von bestimmten, oft ungewünschten Zuständen dieser Objekte, insbesondere in Bezug auf das Vorhandensein von Fehlern (Anomalien), um sie z. B. als NC-Materialien zu deklarieren⁵³⁴. Die realisierten Systeme sind hierbei in der Lage, selbst kleinste Abweichungen in den Eigenschaften der Objekte zu erkennen. Hierzu erfolgt der Einsatz häufig zusammen mit Kamerasystemen, weswegen diese Anwendungen auch gleichzeitig dem KI-Teilbereich des Machine bzw. Computer Vision zuzuordnen sind (siehe Kapitel 2.4.1.3).

Die Bestimmung von Zuständen erfolgt bei weiteren Anwendungen auch für den Betrieb von Maschinen und Fahrzeugen, um Störungen oder Ineffizienzen, wie Fehlfunktionen⁵³⁵ oder hohe Energieverbräuche⁵³⁶, frühzeitig zu erkennen. Hierzu werden Messdaten von verschiedenen Parametern bewertet, u. a. durch die Nutzung zusätzlicher Sensorik, wie Erschütterungssensoren und RFID. Neben dem Maschinenbetrieb können auch menschliche Tätigkeiten überwacht werden, z. B. beim Sortieren von Materialien in Ladungsträgern oder beim Montieren von Bauteilen, um fehlerhafte Aktivitäten zu detektieren⁵³⁷. Hierbei kommen auch sog. Smart Wearables in Form von mit Sensoren ausgestatteten Handschuhen zum Einsatz.

Für die Realisierung der Identifikationsfähigkeit von ML-Anwendungen wird häufig die Lernaufgabe der Klassifikation umgesetzt, indem die Zugehörigkeit der Betrachtungsobjekte zu zuvor festgelegten Klassen ermittelt wird, z. B. in Form von verschiedenen Materialsegmenten und Störungsszenarien. Auch lassen sich mehrere der Anwendungen der Ausreißererkennung zuordnen. Die Lernverfahren entstammen zumeist dem Supervised oder Deep Learning. Demnach werden tiefe NN oder teilweise auch SVM sowie Kombinationen dieser beiden Verfahren genutzt. Eine hohe Bedeutung bei der Entwicklung der entsprechenden Modelle nimmt deren Flexibilität ein, um sie für mehrere, bisher unbekannte Bezugsobjekte anwenden zu können, z. B. zur Identifikation von weiteren, bisher unbekanntem Produkten und Maschinenparametern. In diesem Zusammenhang kommen auch neuartige Konzepte, wie das in Kapitel 4.4.1 vorgestellte Transfer Learning, zum Einsatz⁵³⁸. Gemäß den vorherigen Ausführungen werden in vielen Anwendungsfällen auch spezialisierte Hardwarekomponenten zur Generierung der benötigten Daten eingesetzt. Dementsprechend ist für diese Anwendungen eine Nutzung von

⁵³⁴ Vgl. Carvajal Soto et al. (2019)

⁵³⁵ Vgl. Ma et al. (2018)

⁵³⁶ Vgl. Wang et al. (2018c)

⁵³⁷ Vgl. Kucukoglu et al. (2018)

⁵³⁸ Vgl. Wen et al. (2019)

komplexen Daten in Form von Audio-, Bild- und Videodaten charakteristisch. Die Bereitstellung des systemseitigen Outputs durch die Systeme erfolgt in Echtzeit, um eine kurze Reaktionszeit für die Steuerung der Prozesse zu gewährleisten.

5.2.1.2 Analyse und Bewertung

Das Cluster der Analyse und Bewertung umfasst ML-Anwendungen zur vordergründig punktuellen Ermittlung von bisher unbekanntem Sachverhalten des jeweiligen Anwendungsbereiches, welche für den Menschen nicht oder nur mit großem Aufwand erkennbar sind. Die Systeme erlauben es den Nutzern, für komplexe Problemstellungen mit vielen verschiedenen Merkmalen und einem großen Lösungsraum sinnvolle Auswahlentscheidungen zu treffen.

Mehrere Anwendungen dienen einer Segmentierung von Betrachtungsobjekten in verschiedene, bisher unbekannte Gruppen unter Betrachtung vielfältiger Merkmale. Hierbei kann es sich um Objekte in Form von Materialien bzw. Beständen⁵³⁹ oder auch um Subjekte in Form von Lieferanten⁵⁴⁰ handeln. Auch werden mehrere Anwendungen zur Identifizierung möglicher Störungsszenarien genutzt, z. B. für Maschinen⁵⁴¹, Prozesse⁵⁴² und gesamte Lieferketten⁵⁴³. Im Sinne einer Analyse von Kernursachen (Root Causes) werden dabei diejenigen Einflussfaktoren und deren Kombinationen ermittelt, welche initial zu den Störungen führen. Die ermittelten Segmente oder Szenarien können anschließend von Identifikationsanwendungen für die Zuordnung von zukünftigen Prozessausprägungen genutzt werden (siehe vorheriges Cluster).

Diese Detektion tieferliegender Zusammenhänge wird ebenfalls bei mehreren Anwendungen zur Auswahl geeigneter Entscheidungen aus einem bestehenden Lösungsraum eingesetzt. Hierzu gehört u. a. die Bestimmung geeigneter Geschäftspartner in Form bestehender Kunden oder Lieferanten, indem eine Ähnlichkeit zwischen dem Auftraggeber und -nehmer ermittelt wird⁵⁴⁴. Auch kann eine geeignete Auftragsreihenfolge in der Produktionsplanung anhand bestehender Szenarien⁵⁴⁵ sowie eine geeignete Fahrzeugauswahl anhand unterschiedlicher Antriebstechnologien⁵⁴⁶ bestimmt werden.

Für die Realisierung der Analyse- und Bewertungsfähigkeit werden den ML-Anwendungen stets mehrere Eigenschaften der jeweiligen Betrachtungsobjekte sowie ggf. zusätzliches Hintergrundwissen übergeben, anhand dessen sie Korrelationen oder bedingte Wahrscheinlichkeiten ermitteln. Teilweise liegen dabei bereits Zusammenhänge zwischen Ein- und Ausgangsvariablen in den Daten vor, sodass eher Verfahren zur Klassifikation zum Einsatz kommen. Insbesondere im Falle der Segmentierung sowie der Ermittlung von Störungsszenarien

⁵³⁹ Vgl. Lolli et al. (2019)

⁵⁴⁰ Vgl. Ghorbani et al. (2012)

⁵⁴¹ Vgl. Hiromoto et al. (2017)

⁵⁴² Vgl. Rokach, Hutter (2012)

⁵⁴³ Vgl. Ye et al. (2015)

⁵⁴⁴ Vgl. Hosseini, Khaled (2019)

⁵⁴⁵ Vgl. Lv et al. (2018)

⁵⁴⁶ Vgl. González-Cancelas et al. (2019)

fehlen diese Hintergrundinformationen jedoch, sodass hierfür Verfahren der Gruppierung genutzt werden. Zudem ist auch ein Rückgriff auf die Lernaufgaben der Assoziationsanalyse und der Wissensextraktion festzustellen. Dementsprechend ist der Lernprozess entweder als Supervised oder als Unsupervised Learning gestaltet. Die eingesetzten Lernverfahren sind sehr heterogen, wobei KNN und SVM am häufigsten vertreten sind. Die Bereitstellung der systemseitigen Ergebnisse erfolgt zumeist nur bedarfsbezogen zu bestimmten Zeitpunkten. Hierbei werden teilweise auch die identifizierten Zusammenhänge zu den jeweiligen Ergebnissen mit ausgegeben, um die Verständlichkeit des Lösungsweges für den Nutzer zu erhöhen, z. B. in Form von Wahrscheinlichkeiten, Rankings oder der Feature Importance.

5.2.1.3 Prognose

Die beiden Cluster der Prognose umfassen technische Lösungen zur Ermittlung von zukünftigen Parametern und Zuständen. Hierbei handelt es sich zum einen um individuelle Werte zu den jeweiligen Betrachtungsobjekten, wie z. B. um die Menge, Zeit, Kosten, Qualität und Leistung. Zum anderen können auch bestimmte Ereignisse oder das Verhalten von Prozessen oder Akteuren prognostiziert werden. Dies beinhaltet auch eine Ermittlung unterschiedlicher Planungsszenarien.

Viele der Anwendungen dienen der Ermittlung der zukünftigen Nachfrage von Kunden, d. h. dem Demand Forecasting. Hierzu existieren verschiedene Variationen, die sich sowohl hinsichtlich der Bezugsobjekte als auch hinsichtlich des Prognosezeitraums unterscheiden. Letzterer reicht von Stunden oder Tagen über Monate bis hin zu Jahren, wobei festzustellen ist, dass hierfür jeweils unterschiedliche Lösungen notwendig sind. Ziel dieser Anwendungen ist es, anhand unterschiedlicher Einflussfaktoren, wie der Tageszeit und des Wetters, entweder die Nachfragemenge oder das Verhalten der Kunden zu bestimmen⁵⁴⁷. Hierzu zählt auch die Prognose der auslösenden Akteure von zukünftigen Bestellungen⁵⁴⁸. Im Zusammenhang mit der Nachfrageprognose stehen auch Anwendungen zur Ermittlung der zukünftigen Kosten für bestimmte Produkte⁵⁴⁹ oder Prozesse⁵⁵⁰ sowie deren absatzseitiges Äquivalent in Form von Preisen⁵⁵¹. Neben der Nachfrage werden auch weitere Mengenangaben mit hoher Relevanz für die Logistik prognostiziert, z. B. das zukünftige Güteraufkommen in Form der Containeranzahl⁵⁵² sowie die voraussichtliche Produktionsmenge⁵⁵³. Auch wird die zukünftig verfügbare Kapazität zur „Deckung“ dieser nachgefragten Mengen bestimmt, z. B. in Form der Materialbestände an bestimmten Standorten⁵⁵⁴.

⁵⁴⁷ Vgl. Yang, Sutrisno (2018)

⁵⁴⁸ Vgl. Silva et al. (2017)

⁵⁴⁹ Vgl. Karaoglan, Karademir (2017)

⁵⁵⁰ Vgl. Ning et al. (2020)

⁵⁵¹ Vgl. Puchalsky et al. (2018)

⁵⁵² Vgl. Tian et al. (2013)

⁵⁵³ Vgl. Cheng, Tang (2018)

⁵⁵⁴ Vgl. Santis et al. (2017)

Bei weiteren Anwendungen wird die zukünftige Leistung von Lieferketten⁵⁵⁵ sowie von einzelnen Maschinen und logistischen Anlagen ermittelt, z. B. in Form der Fördertechnik⁵⁵⁶. Dies erfolgt auch in Bezug auf bedeutende Kennzahlen, wie die OEE, d. h. die Gesamtanlagen- und Maschineneffektivität⁵⁵⁷. Im Zusammenhang mit diesen leistungsbezogenen Prognosen steht auch die Qualität, welche von mehreren Anwendungen in ihrer zukünftigen Ausprägung ermittelt wird. Dies umfasst Qualitätsprognosen von Produkten in oder nach deren Fertigung⁵⁵⁸, um vorab die potenzielle Nacharbeit oder die Abhängigkeit des Produktionsprozesses von einzelnen Faktoren bestimmen zu können⁵⁵⁹. Bei anderen Anwendungen wird wiederum die Qualität einzelner Maschinen prognostiziert, z. B. zur Bestimmung ihrer Abnutzung für eine Antizipation notwendiger Instandhaltungsmaßnahmen⁵⁶⁰, was als Predictive Maintenance bezeichnet wird. Zudem lässt sich die zukünftige Leistung bzw. Qualität von Geschäftspartnern in Bezug auf bestimmte Zielgrößen prognostizieren, um deren Eignung zu bewerten. Dies gilt für bestehende Lieferanten⁵⁶¹, aber auch für potenzielle Wertschöpfungspartner⁵⁶². Auch werden Ereignisse prognostiziert, welche die Qualität und Leistung von logistischen Betrachtungsobjekten beeinflussen, z. B. in Form von spezifischen Störungen, wie Schäden an eingehenden Lieferungen⁵⁶³ oder Staus bei Transporten⁵⁶⁴, sowie in Form allgemeiner Risiken in Lieferketten⁵⁶⁵. Ein weiterer wichtiger Planungsparameter, der von mehreren Anwendungen prognostiziert wird, betrifft die Dauer von Prozessen, welche für Transporte⁵⁶⁶ und Produktionsprozesse⁵⁶⁷, aber auch für die gesamte Durchlaufzeit (DLZ) von Kundenaufträgen⁵⁶⁸ ermittelt wird.

Sofern es sich bei der zu prognostizierenden Größe um eine numerische Variable handelt, wird bei den Anwendungen eine Regression umgesetzt, was auf ca. 80 % der Fälle zutrifft. Bei qualitativen Variablen handelt es sich um eine Klassifikation. Die verwendeten Verfahren sind häufig dem Supervised bzw. Deep Learning, aber auch teilweise dem Evolutionay Learning zuzuordnen. In etwa der Hälfte der Fälle werden KNN eingesetzt; die übrigen Systeme nutzen u. a. evolutionäre Algorithmen, weitere NN-Architekturen, entscheidungsbaumbasierte Verfahren, SVM und Bayes-Verfahren. Insbesondere bei diesem Clustern zeigt sich, dass einzelne Lernaufgaben durch viele verschiedene Lernverfahren realisierbar sind, was die Erkenntnisse aus der Literaturanalyse in Kapitel 4.1.2 bestätigt. Die Bereitstellung der systemseitigen Ergebnisse erfolgt zumeist punktuell in regel- oder unregelmäßigen Abständen.

⁵⁵⁵ Vgl. Lima-Junior, Carpinetti (2019)

⁵⁵⁶ Vgl. Singh et al. (2012)

⁵⁵⁷ Vgl. Brunelli et al. (2019)

⁵⁵⁸ Vgl. Papananias et al. (2019)

⁵⁵⁹ Vgl. Wang et al. (2012)

⁵⁶⁰ Vgl. Luo et al. (2015)

⁵⁶¹ Vgl. Fallahpour et al. (2017)

⁵⁶² Vgl. Mori et al. (2012)

⁵⁶³ Vgl. Lau et al. (2013)

⁵⁶⁴ Vgl. Bhattacharya et al. (2014)

⁵⁶⁵ Vgl. Baryannis et al. (2019a)

⁵⁶⁶ Vgl. Owczarek, Janke (2018)

⁵⁶⁷ Vgl. Wang et al. (2018b)

⁵⁶⁸ Vgl. Singh, Soni (2019)

Entsprechend der initialen Ausführungen zur entwickelten Typologie entfallen die Prognoseanwendungen auf zwei Cluster. Deren Unterscheidung kann anhand der entwicklungsseitigen Rahmenbedingungen vorgenommen werden. Mit dem Cluster „Prognose I“ existiert eine Gruppe von Anwendungen, in denen bereits erfolgreich – im Kontext der jeweiligen Problemstellung – erprobte Lernverfahren zum Einsatz kommen. Die entwickelten Systeme weisen dabei einen vergleichsweise hohen technischen Reifegrad auf, indem sie u. a. über einen erweiterten Funktionsumfang verfügen, z. B. in Form der Ausgabe von prognosebasierten Maßnahmen, oder an andere Systeme zur Ergebnisbereitstellung angebunden sind. Dies trifft insbesondere auf Anwendungen für bereits häufiger umgesetzte Problemstellungen zu, wie Nachfrage- und Qualitätsprognosen zu logistischen Bezugsobjekten. Die Anwendungen des Clusters „Prognose II“ nutzen stattdessen – im logistischen Kontext – vergleichsweise unerprobte Lernverfahren, wie CNN und RNN, oder auch Kombinationen mehrerer Algorithmen. Das Ziel liegt hierbei weniger in der Erhöhung des technischen Reifegrades als eher in der Realisierung einer höheren Ergebnisqualität gegenüber den bisherigen ML-Ansätzen.

5.2.1.4 Optimierung

Die ML-Anwendungen des Optimierungsclusters dienen der Ermittlung optimaler Parameter und Strategien gemäß festgelegter Zielgrößen und Restriktionen. Anders als beim Cluster der Analyse und Bewertung entstammen die Lösungen keinem vorab bekannten Lösungsraum, sondern werden stets neu generiert. Daher können sie auch eher „unkonventionell“ ausfallen, sodass im übertragenen Sinne auch von einer kreativen Fähigkeit gesprochen werden kann.

Die meisten Anwendungen in diesem Cluster betreffen die auftragsbezogene Optimierung der Belegung einzelner Maschinen oder Arbeitsstationen (sog. Shops)⁵⁶⁹. Dies umfasst sowohl die initiale Festlegung einer optimalen Auftragszuordnung (Produktionsplanung) als auch deren zielgerichtete Anpassung im Falle von produktionsseitigen Veränderungen (Produktionssteuerung), z. B. bei Störungen oder Änderungswünschen von Kunden⁵⁷⁰. Bei den zu mini- bzw. maximierenden Zielgrößen handelt es sich u. a. um die Durchlaufzeit, die Bestandshöhe oder die pünktliche Fertigstellung der Aufträge, d. h. die OTD (On Time Delivery). Gleichzeitig werden mehrere statische und teilweise dynamische Restriktionen berücksichtigt. Während Ersteres u. a. die produktbezogene Bearbeitungsreihenfolge umfasst, adressiert Letzteres auch kurzfristige Veränderungen, wie die derzeitige Systembelastung, die jeweilige Anzahl an offenen Aufträgen oder Störungen. Entsprechend der Vielzahl an Zielen und Einflussfaktoren sowie der Kombinationsmöglichkeiten im Falle von mehreren Arbeitsstationen und Produkten entstehen sehr komplexe Probleme, die erfolgreich durch die entwickelten ML-Anwendungen gelöst werden. Dies umfasst auch Belegungsplanungen für gesamte Produktionssysteme⁵⁷¹.

⁵⁶⁹ Vgl. Wang et al. (2017a); Nasiri et al. (2017)

⁵⁷⁰ Vgl. Zheng et al. (2019)

⁵⁷¹ Vgl. Zhang et al. (2014)

Die optimale Allokation von Aufträgen findet sich auch für weitere Probleme abseits der Produktion, wie in Form der auftragsbezogenen Disposition von Transporten⁵⁷², bei der ebenfalls verschiedene Variablen, wie die Auslastung der einzelnen Transporte und die Lieferzeit, berücksichtigt werden. Auch für die Ermittlung optimaler Entscheidungen zur eigenen oder externen Realisierung von Kundenaufträgen (Make-or-buy) unter Berücksichtigung verschiedener Variablen, wie die Kosten, die Auslastung oder die Durchlaufzeit, existieren Anwendungen⁵⁷³. Eine weitere bedeutende logistische Problemstellung in Form der Bestimmung der bestmöglichen Transportstrecke (sog. Routing) wird ebenfalls von mehreren Optimierungsanwendungen realisiert⁵⁷⁴.

Neben der Ermittlung von Strategien, d. h. der Sequenz mehrerer Aktionen, umfassen viele Anwendungen auch eine Optimierung individueller Parameter. Diese können sich allgemein auf Prozesse⁵⁷⁵ oder auf bestimmte Maschinen⁵⁷⁶ beziehen, z. B. in Form von Losgrößen und Betriebszeiten. Ferner werden auch optimale Verkaufspreise von Dienstleistungen oder Produkten ermittelt. Bei mehreren Anwendungen zeigt sich auch eine integrative Fähigkeit von ML, indem gleichzeitig mehrere Zielgrößen harmonisiert werden. Dies bezieht sich u. a. auf eine Ermittlung optimaler Bestell- und Bestandsmengen in Bezug auf die Zeit und Kosten über mehrere Stufen der Lieferketten zur Reduzierung damit verbundener Schwankungen in Form des Bullwhip-Effektes. Auch werden optimale Planungen zwischen verschiedenen Bereichen realisiert, wie zwischen der Produktions- und Instandhaltungsplanung oder der Produktions- und Transportplanung zur Maximierung der Materialverfügbarkeit in Just-in-Time-Szenarien.

Zur Realisierung der Anwendungen dieses Clusters werden zumeist Lernverfahren des Reinforcement Learning und des Evolutionary Learning eingesetzt, wie Q-Learning, Team Progress Algorithm und NSGA-II. Die Bereitstellung der Ergebnisse erfolgt teilweise punktuell, z. B. bei einer auftragsbezogenen Produktionsplanung, aber auch häufig permanent, wie im Falle des Routings. Bei mehreren Anwendungen ist zudem bereits eine Verbindung mit entsprechenden Ausführungssystemen, z. B. MES, festzustellen.

5.2.2 Logistische Entscheidungsprozesse

Die sieben identifizierten Typen zur prozessualen Dimension von ML-Anwendungen repräsentieren unterschiedliche Bereiche von logistischen Entscheidungsprozessen, für deren Ausführung bzw. Unterstützung diese Systeme eingesetzt werden können. Ausgehend von einer Zusammenfassung in Tabelle 14 werden die einzelnen Typen in den nachfolgenden Abschnitten charakterisiert.

⁵⁷² Vgl. Irannezhad et al. (2020)

⁵⁷³ Vgl. Li et al. (2012)

⁵⁷⁴ Vgl. Cao et al. (2020); Becker et al. (2016)

⁵⁷⁵ Vgl. Yin et al. (2020)

⁵⁷⁶ Vgl. Doltsinis et al. (2014)

Lieferantenmanagement	Produktionsplanung und -steuerung	Transportmanagement	Prozessmonitoring	Supply Chain Risk und Performance Management
<p>Planungs- und Steuerungsaufgaben zur Einbindung von externen Wertschöpfungspartnern</p> <p>Sicherstellung der Lieferbereitschaft und Qualität der eingebundenen Partner zur anforderungsgerechten Bedienung der Nachfrage</p>	<p>Planungs- und Steuerungsaufgaben zur kurz- bis mittelfristigen Gestaltung des Produktionssystems</p> <p>Effizienzsteigerung der Produktionsprozesse durch die Reduzierung von Durchlaufzeiten und die Steigerung der Produktivität</p>	<p>Planungs- und Steuerungsaufgaben zur kurz- bis mittelfristigen Gestaltung des inner- und außerbetrieblichen Transportsystems</p> <p>Effizienz- und Qualitätssteigerung von Transporten, v. a. durch die Optimierung der dazugehörigen Wege und Zeiten</p>	<p>Überwachungsaufgaben zur Ermittlung von qualitäts- und leistungsbezogenen Zuständen des innerbetrieblichen Materialflusses</p> <p>Transparenzschaffung zur kurzfristigen Anpassung für eine höhere Produkt- und Prozessqualität</p>	<p>Überwachungsaufgaben zur Ermittlung von Ereignissen und Zuständen in Lieferketten</p> <p>Transparenzschaffung zur Initiierung von v. a. längerfristigen Verbesserungsmaßnahmen für eine höhere Effizienz und Robustheit von Lieferketten</p>
<ul style="list-style-type: none"> - Bewertung und Auswahl von Lieferanten und Dienstleistern, sowohl bei bestehenden als auch bei neuen Partnerschaften - Ermittlung der optimalen Lieferstrategien - Ermittlung zukünftiger Störungen und Fehler bei Lieferungen 	<ul style="list-style-type: none"> - Make-or-Buy-Entscheidungen für eingehende Kundenaufträge - Bestimmung der zukünftigen und optimalen Auftragsreihenfolge sowie der Maschinen- und Arbeitsplatzbelegung - Ermittlung optimaler Produktions- und Maschinenparameter 	<ul style="list-style-type: none"> - Bestimmung der zukünftigen und optimalen Disposition von Transportaufträgen - Bestimmung geeigneter Verpackungen sowie Beladung von Fahrzeugen - Ermittlung optimaler Routen von Fahrzeugen - Bestimmung zukünftiger Fahrpläne und Ankunftszeiten 	<ul style="list-style-type: none"> - Erkennung von Anomalien an Materialien und Produkten - Erkennung von Störungen bei manuellen Abläufen sowie an Maschinen und Betriebsmitteln, inkl. von Wartungsbedürfnissen - Bestimmung aggregierter Qualitäts- und Leistungsmerkmale von Prozessen, Materialien und Maschinen 	<ul style="list-style-type: none"> - Bestimmung von Risiken und Störungen in Lieferketten, inkl. Root Causes - Erkennung von Anomalien bei ausgelieferten Produkten - Bestimmung der Leistung von Lieferketten
<ul style="list-style-type: none"> - Bezug zu externen Akteuren und Entwicklungen - Parteilich durch konventionelle Entscheidungstechniken unterstützt, v. a. deskriptive Analysen 	<ul style="list-style-type: none"> - Bezug zu einzelnen Aufträgen, Maschinen und Prozessen sowie zu gesamten Produktionssystemen - Häufig durch konventionelle Entscheidungstechniken unterstützt, v. a. mathematische Optimierungen und Heuristiken 	<ul style="list-style-type: none"> - Bezug zu Transportaufträgen, Strecken und Fahrzeugen bzw. gesamten Transportketten - Bisher zumeist manuell umgesetzt; bei Routing bereits fortgeschrittene Techniken, jedoch nur Verkehrsbeobachtung 	<ul style="list-style-type: none"> - Bezug zu einzelnen Aufträgen und Materialien oder zu Prozessen und den darin eingesetzten technischen und menschlichen Ressourcen - Häufig durch konventionelle Entscheidungstechniken unterstützt, v. a. klassische statistische Verfahren mit Soll-Ist-Vergleichen 	<ul style="list-style-type: none"> - Zumeist kein Auftragsbezug, sondern übergreifende Betrachtung von Netzwerken, Prozessen oder Akteuren - Bisher oft manuell durchgeführt oder durch deskriptive Analysen unterstützt

Merkmal	Bedarfs- und Kapazitätsmanagement
Langfristige Beschaffungs- und Absatzplanung Logistische Aufgaben	Planungs- und Steuerungsaufgaben zur kurz- bis mittelfristigen Bestimmung und Harmonisierung von Materialbedarfen und -kapazitäten
Ziel	Bedarfsgerechte Bereitstellung der Ressourcen zur Kostensenkung und Qualitätssteigerung, u. a. durch Abbau von Risikopuffern
Anwendungsfälle	<ul style="list-style-type: none"> - Bestimmung der kurzfristigen Nachfrage- sowie der erwarteten Material- und Produktionsmengen - Bewertung der Bestandssituation - Ermittlung zukünftiger Bestellmengen und -zeitpunkte, auch für mehrere Standorte - Ermittlung von Auftragsdurchlaufzeiten und Prozesskosten
Bezugsobjekte und bisherige Ausführung	<ul style="list-style-type: none"> - Bezug zu einzelnen Materialien, Aufträgen und eingesetzten Ressourcen - Häufig durch konventionelle Entscheidungstechniken unterstützt, v. a. klassische statistische Verfahren und deterministische Ansätze

Tabelle 14: Zusammenfassung der Typen für die logistischen Entscheidungsprozesse

5.2.2.1 Langfristige Beschaffungs- und Absatzplanung

Die ML-Anwendungen des Clusters der langfristigen Beschaffungs- und Absatzplanung (LBA) beziehen sich auf taktisch-strategische Planungsaufgaben zur Gestaltung von beschaffungs- und absatzmarktseitigen Logistikstrukturen. Es werden einerseits wichtige Parameter zur Bestimmung der zukünftigen Auftragsituation und der damit verbundenen logistikrelevanten Mengenströme erhoben sowie andererseits Auswahlentscheidungen zur langfristigen Kooperation mit Wertschöpfungspartnern und Kunden getroffen. Ziel des Einsatzes von ML ist eine langfristige Erhöhung der Effizienz, Flexibilität und Servicequalität von logistischen Systemen durch die Bereitstellung zentraler Planungsinformationen für nachfolgende Entscheidungsprozesse. Die meisten der adressierten Aufgaben werden in den Unternehmen aktuell noch manuell durchgeführt, was auf die hohe Individualität der Problemstellungen zurückzuführen ist.

Mehrere Anwendungen in diesem Cluster dienen der Ermittlung der zukünftigen Nachfrage von Kunden in einem mittel- bis langfristigen Planungshorizont, wofür die Prognosefähigkeit von ML umgesetzt wird. Die Nachfrageprognosen beziehen sich sowohl auf bestimmte Kundenmärkte in Form einzelner Produktgruppen als auch auf die daraus resultierenden Absatzmengen und den Umsatz⁵⁷⁷. Auch wird durch einige Systeme das Nachfrageverhalten der

⁵⁷⁷ Vgl. Martínez et al. (2020)

Kunden in Bezug auf dynamische Preisveränderungen bestimmt, um zukünftige Verkaufspreise zielgerichtet festzulegen. Dazu erfolgt eine Prognose der erwarteten Kaufkraft je Preisbereich für verschiedene Kundengruppen⁵⁷⁸. Ebenfalls wird in diesem Zusammenhang die zukünftige Entwicklung der Verkaufspreise von Produkten ermittelt⁵⁷⁹. Ein weiterer Anwendungsfall dieses Clusters beinhaltet die strategische Auswahl geeigneter Geschäftspartner in Form von Kunden sowie von Zulieferern und Dienstleistern (sog. Supplier Selection). Dabei wird u. a. die jeweilige Eignung der potenziell infrage kommenden Unternehmen für eine Geschäftsbeziehung anhand von unterschiedlichen wirtschaftlichen Merkmalen ermittelt, wie die Größe, der Standort und das Wettbewerbsumfeld⁵⁸⁰, aber auch anhand der Prognose der erwarteten Lieferperformance⁵⁸¹.

5.2.2.2 Bedarfs- und Kapazitätsmanagement

Das Cluster des Bedarfs- und Kapazitätsmanagements (BKM) umfasst Anwendungen für Planungs- und Steuerungsaktivitäten zur kurz- bis mittelfristigen Bestimmung und Harmonisierung von benötigten und verfügbaren logistischen Kapazitäten, wobei dies vordergründig auf den Materialbedarf zutrifft. In diesem Zusammenhang werden auch Leistungsgrößen, wie Bestände, Durchlaufzeiten und Kosten, mitberücksichtigt. Ziel des Einsatzes der Anwendungen ist eine bedarfsgerechte Bereitstellung der Ressourcen, die neben einer Steigerung der logistischen Servicequalität und der Vermeidung von Out-of-Stock-Situationen auch zu einer Reduktion von Ineffizienzen in Form von Überkapazitäten und unnötigen Risikopuffern beiträgt. Die adressierten Aufgaben werden bereits in vielen Fällen durch andere Entscheidungstechniken unterstützt, z. B. in Form von APS-Systemen (Advanced Planning and Scheduling) und MRP-Systemen (Material Requirements Planning), welche jedoch auf modellgestützten Ansätzen oder klassischen statistischen Verfahren basieren und daher die Wechselwirkungen und Dynamik der Planungsparameter nur eingeschränkt berücksichtigen können.

Zur Ermittlung des Materialbedarfs wird auch von Anwendungen aus diesem Cluster die Kundennachfrage prognostiziert – jedoch für einen vergleichsweise kurzen Zeithorizont⁵⁸². Anstelle dieser absatzseitigen Betrachtung bestimmen weitere Systeme die korrespondierenden logistischen Mengen, z. B. in Form des erwarteten Güteraufkommens in logistischen Knotenpunkten⁵⁸³ und der zukünftigen Produktionsmenge, um diese beim S&OP-Prozess nutzen zu können⁵⁸⁴. Neben dem Materialbedarf wird auch die dafür notwendige Kapazität durch mehrere Anwendungen adressiert. Dies umfasst die Bestimmung zukünftiger Szenarien von Ma-

⁵⁷⁸ Vgl. Gupta, Pathak (2014)

⁵⁷⁹ Vgl. Puchalsky et al. (2018)

⁵⁸⁰ Vgl. Mori et al. (2012)

⁵⁸¹ Vgl. Fallahpour et al. (2017)

⁵⁸² Vgl. Yang, Sutrisno (2018)

⁵⁸³ Vgl. Tian et al. (2013)

⁵⁸⁴ Vgl. Clercq et al. (2019)

materialbeständen und möglicher Lieferrückstände (sog. Backorders) an verschiedenen Standorten⁵⁸⁵. Unter Nutzung der Analyse- und Bewertungsfähigkeit erfolgt dazu auch eine Segmentierung der Bestände in verschiedene Materialarten⁵⁸⁶. Zudem werden für Logistiknetzwerke, bestehend aus mehreren Lagerstandorten, die erforderlichen Materialmengen zur Sicherstellung einer bedarfsgerechten Kapazität ausgehend vom zukünftigen Materialbedarf bestimmt⁵⁸⁷. Im Falle der Beauftragung externer Wertschöpfungspartner zur Bereitstellung benötigter Materialumfänge werden sowohl die notwendigen Bestellmengen⁵⁸⁸, u. a. unter Berücksichtigung von Kapazitäten, Preisen und der Nachfrage, als auch dafür geeignete Bestellzeitpunkte⁵⁸⁹ ermittelt. Als Grundlage für die Bedarfs- und Kapazitätsplanungen erfolgt außerdem eine Prognose der voraussichtlichen Durchlaufzeit zur Realisierung von Aufträgen von der Bestellung bis zur Auslieferung⁵⁹⁰ sowie der zu erwartenden Prozess- und Materialkosten⁵⁹¹.

5.2.2.3 Lieferantenmanagement

Die ML-Anwendungen des Clusters des Lieferantenmanagements (LM) beziehen sich auf Planungs- und Steuerungsaufgaben zur Einbindung von externen Wertschöpfungspartnern. Diese dabei abgedeckten Entscheidungsprozesse reichen von der Auswahl und Bewertung der entsprechenden Unternehmen über die Gestaltung der damit verbundenen Prozesse bis zur Intervention bei Abweichungen. Ziel des Einsatzes der Anwendungen ist die Sicherstellung der Lieferbereitschaft und Qualität der eingebundenen Partner, um die Kundennachfrage anforderungsgerecht zu bedienen. Mehrere der adressierten Problemstellungen werden bereits durch konventionelle Entscheidungstechniken unterstützt, wie z. B. Scoring-Modelle zur Lieferantenbewertung oder ERP-Systeme (Enterprise-Resource-Planning) zur Berechnung optimaler Bestellmengen. Tiefgreifende Zusammenhänge und dynamische Veränderungen können von den zugrundeliegenden univariaten Analysen und deterministischen Verfahren jedoch nicht berücksichtigt werden.

Mehrere Anwendungen dieses Clusters dienen der Bestimmung geeigneter Lieferanten und Logistikdienstleister, wobei sowohl die ML-Fähigkeiten der Analyse und Bewertung als auch der Optimierung eingesetzt werden. Neben einer initialen Beauftragung neuer Unternehmen beziehen sich die entsprechenden Anwendungsfälle auch auf die kontinuierliche Bewertung bestehender Partner⁵⁹². Während bei ersterem allgemeine Unternehmensinformationen berücksichtigt werden, sehen letztere eine Einbindung von Leistungsdaten aus vergangenen Aufträgen vor, wie Informationen zur OTD und zu verursachten NC-Materialien. In diesem Zusam-

⁵⁸⁵ Vgl. Santis et al. (2017)

⁵⁸⁶ Vgl. Lolli et al. (2019)

⁵⁸⁷ Vgl. Ren et al. (2020)

⁵⁸⁸ Vgl. Sustrova (2016); Abbasi et al. (2020)

⁵⁸⁹ Vgl. Inprasit, Tanachutiwat (2018)

⁵⁹⁰ Vgl. Singh, Soni (2019)

⁵⁹¹ Vgl. Ning et al. (2020); Karaoglan, Karademir (2017)

⁵⁹² Vgl. Cavalcante et al. (2019)

menhang erfolgt auch eine Betrachtung weiterer lieferantenseitiger Fähigkeiten, wie die Flexibilität bei Nachfrageänderungen oder Störungen⁵⁹³. Das systemseitige Ergebnis stellt bei diesen Anwendungen häufig ein Ranking der Lieferanten dar, welches der Auswahlentscheidung oder einer gezielten Förderung im laufenden Betrieb dient. Für eine geeignete Einbindung der Lieferanten in das Wertschöpfungsnetzwerk werden zudem optimale Lieferstrategien ermittelt, insbesondere in Bezug auf die Bestellmenge und -frequenz. Dies erfolgt u. a. mit dem Ziel einer Minimierung der kundenseitigen Wartezeit⁵⁹⁴ oder einer Verringerung des Bullwhip-Effektes entlang der Lieferkette⁵⁹⁵. Um frühzeitig bei potenziellen Störungen der beauftragten Partner eingreifen zu können, werden diese Ereignisse sowie damit verbundene Auswirkungen in Bezug auf die Lieferfähigkeit von mehreren Anwendungen bestimmt. Dies erfolgt zumeist durch den Rückgriff auf die Prognosefähigkeit von ML, indem voraussichtliche Lieferrückstände entlang der Lieferkette⁵⁹⁶ oder Fehler im Materialhandling⁵⁹⁷ ermittelt werden.

5.2.2.4 Produktionsplanung und -steuerung

Das Cluster der Produktionsplanung und -steuerung (PPS) umfasst ML-Anwendungen zur Bestimmung zentraler logistischer Planungsparameter für die ablauforganisatorische Gestaltung von Produktionssystemen. Die dazugehörigen Planungs- und Steuerungsaufgaben beziehen sich auf die Gesamtheit des Produktionssystems, auf größere Teilbereiche oder auf einzelne Maschinen bzw. Prozessschritte und dienen u. a. der Terminplanung, Reihenfolgeplanung und Maschinenbelegung, inkl. der Losgrößenermittlung. Ziel des Einsatzes von ML ist eine Effizienzsteigerung der Produktionsprozesse durch die Reduzierung von Durchlaufzeiten und die Steigerung der Produktivität. Die adressierten Problemstellungen werden in der Praxis bereits häufig durch andere Entscheidungstechniken unterstützt, insbesondere durch klassische PPS-Systeme, aber auch durch MES und APS-Systeme. Diese basieren jedoch zumeist auf Heuristiken oder mathematischen Optimierungen und sind daher nur bedingt in der Lage, alle relevanten Einfluss- und Zielgrößen und deren Dynamik zu berücksichtigen.

Die meisten Anwendungen dieses Clusters dienen entweder der initialen Festlegung eines Produktionsplans zur geeigneten auftragsbezogenen Belegung von Arbeitsstationen und Maschinen oder dessen kontinuierlicher Anpassung in Hinblick auf neue Rahmenbedingungen. Letzteres umfasst auch eine Berücksichtigung von Störungen⁵⁹⁸ oder vom gegenwärtigen Umlaufbestand⁵⁹⁹ bei der Ermittlung des Produktionsplans. Neben einer Durchlaufzeitenreduzierung umfassen die dabei zu optimierenden Zielgrößen auch eine Einhaltung kundenseitiger Termine und die Auslastungserhöhung, sodass auch das Problem der gleichzeitigen Optimie-

⁵⁹³ Vgl. Hosseini, Khaled (2019)

⁵⁹⁴ Vgl. Mortazavi et al. (2015)

⁵⁹⁵ Vgl. Sun, Zhao (2012)

⁵⁹⁶ Vgl. Silva et al. (2017)

⁵⁹⁷ Vgl. Gürbüz et al. (2019)

⁵⁹⁸ Vgl. Worapradya, Thanakijkasem (2015)

⁵⁹⁹ Vgl. Zhang et al. (2014)

nung der Durchlaufzeiten und Kapazitätsauslastung in Form des „Dilemmas der Ablaufplanung“ Berücksichtigung findet. Zudem wird die Harmonisierung mit angrenzenden Prozessen, z. B. der Instandhaltungsplanung⁶⁰⁰, als Ziel verfolgt. Insgesamt decken die Anwendungen zur Bestimmung des Produktionsplans verschiedene Ausprägungen von Produktionssystemen ab, wie Flow Shop, Open Shop und Job Shop⁶⁰¹, welche sich im Wesentlichen hinsichtlich der Freiheitsgrade bei der Nutzung verschiedener Maschinen und deren Reihenfolge für die Bearbeitung von Aufträgen unterscheiden. Auch der Anwendungsfall einer Mehrvariantenproduktion wird unter Rückgriff auf die Fähigkeit der Analyse und Bewertung berücksichtigt⁶⁰². Unter Einbeziehung der genannten Rahmenbedingungen von Produktionssystemen, wie die aktuelle Auslastung und Durchlaufzeit, umfassen einige Anwendungen auch eine Ermittlung optimaler Entscheidungen für die Annahme oder Ablehnung neuer Produktionsaufträge sowie – im Falle einer Annahme – für deren Eigen- oder Fremdfertigung⁶⁰³. Auch liegen Anwendungen in diesem Cluster vor, welche die Ermittlung einzelner Prozess- und Maschinenparameter adressieren, wobei unterschiedliche ML-Fähigkeiten zum Einsatz kommen. Dies umfasst die Identifikation des Energieverbrauchs von Maschinen⁶⁰⁴, die Prognose der Durchlaufzeit in der Produktion⁶⁰⁵ sowie die Bestimmung optimaler Betriebsparameter für die Erhöhung der Prozessqualität⁶⁰⁶. Hierbei werden auch „instabile“ Produktionsszenarien abgedeckt, wie die Realisierung einer robusten Anlaufphase durch eine Störungsminimierung⁶⁰⁷.

5.2.2.5 Transportmanagement

Die ML-Anwendungen des Clusters des Transportmanagements (TM) betreffen Planungs- und Steuerungsaufgaben zur Gestaltung des inner- und außerbetrieblichen Transportsystems. Dies umfasst die Bestimmung der Transportmittel, der Transportprozesse und des Handlings der Transportgüter, einschließlich der transportseitigen Schnittstellenaufgaben, z. B. der Verpackungsplanung. Ziel der Anwendungen ist eine Effizienz- und Qualitätssteigerung von Transporten, v. a. durch die Optimierung der dazugehörigen Wege und Zeiten. Mehrere der Entscheidungsprozesse werden aktuell vordergründig manuell ausgeführt, insbesondere die Dispositionstätigkeiten. Andere Probleme, wie das Routing, werden bereits mit fortgeschrittenen Techniken unterstützt, wobei die in diesem Falle eingesetzten Navigationssysteme zu meist nur verkehrsbezogene Informationen berücksichtigen.

Ein bedeutender Anwendungsfall stellt die angesprochene Disposition von Aufträgen zu unterschiedlichen Transportmöglichkeiten dar. Hierzu existieren zum einen Prognoseanwendungen, welche das zukünftige Verhalten von Disponenten ermitteln⁶⁰⁸, zum anderen wird mittels

⁶⁰⁰ Vgl. Liu et al. (2018)

⁶⁰¹ Vgl. Wang et al. (2017a); Nasiri et al. (2017)

⁶⁰² Vgl. Lv et al. (2018)

⁶⁰³ Vgl. Li et al. (2012)

⁶⁰⁴ Vgl. Zhang, Jiang (2020)

⁶⁰⁵ Vgl. Lingitz et al. (2018)

⁶⁰⁶ Vgl. Yin et al. (2020)

⁶⁰⁷ Vgl. Doltsinis et al. (2014)

⁶⁰⁸ Vgl. Maghrebi et al. (2015)

der Optimierungsfähigkeit von ML die geeignete Zuordnung für Aufträge zur Minimierung von Kosten bestimmt⁶⁰⁹. Neben der Auswahl bestimmter Fahrzeuge beziehen sich einzelne Anwendungen auch auf die optimale Konfiguration der gesamten Transportkette, welche aus mehreren Teilprozessen mit unterschiedlichen Verkehrsmitteln bestehen kann. Diese umfasst auch eine auftragsbezogene Bewertung der Durchführung eines Cross-Dockings oder einer Direktbelieferung. Zudem wird eine geeignete Bündelung von Sendungen für die Laderaumoptimierung bestimmt, indem verschiedene Eigenschaften der Güter, wie die Größe, Konsistenz und eine notwendige Temperaturführung, Berücksichtigung finden. Ein weiterer bedeutender Anwendungsfall bezieht sich auf die Ermittlung eines optimalen Streckenverlaufs für Transporte in Hinblick auf eine Reduzierung von deren Kosten und Zeiten oder – im Falle von eng getakteten Lieferketten – in Bezug auf den Produktionsplan⁶¹⁰. Die entsprechenden Anwendungen decken dabei sowohl In- und Outbound-Verkehre als auch innerbetriebliche Transporte ab⁶¹¹. Hierbei werden zentrale Probleme der Logistik in Form des Traveling Salesman Problems sowie des Vehicle Routing Problems gelöst. Im Zusammenhang mit dem Routing werden auch zukünftige Ereignisse und Einflüsse prognostiziert, die eine Veränderung der Streckenverläufe erfordern, wie z. B. Staus⁶¹². Als zentraler Parameter für das Transportmanagement sowie für weitere logistische Planungsaktivitäten werden bei einzelnen Anwendungen auch die Prozess- bzw. Ankunftszeiten von Fahrzeugen sowie von gesamten Transportketten in Form der ETA bestimmt, anhand derer sich Verspätungen feststellen lassen⁶¹³.

5.2.2.6 Prozessmonitoring

Die ML-Anwendungen des Clusters des Prozessmonitorings (PM) beziehen sich auf Überwachungsaufgaben zur leistungs- und qualitätsbezogenen Zustandsermittlung des innerbetrieblichen Materialflusses. Dies betrifft sowohl spezifische Materialien, Produkte und Aufträge als auch eine auftragsunabhängige Kontrolle von Prozessen sowie der beteiligten technischen und personellen Ressourcen. Ziel des Einsatzes dieser Anwendungen ist die Erzielung einer höheren Transparenz über die jeweiligen Bezugsobjekte, um kurzfristig Anpassungsmaßnahmen, u. a. zur Sicherstellung der Lieferfähigkeit, initiieren zu können. Die adressierten Probleme werden bereits häufig durch andere Entscheidungstechniken unterstützt, insbesondere in Form deskriptiver Analysen in Verbindung mit Soll-Ist-Vergleichen zur statistischen Prozesskontrolle. Auch hierbei werden allerdings keine tieferliegenden Zusammenhänge und keine zukünftigen Zustände ermittelt.

⁶⁰⁹ Vgl. Irannezhad et al. (2020)

⁶¹⁰ Vgl. Cao et al. (2020)

⁶¹¹ Vgl. Becker et al. (2016)

⁶¹² Vgl. Di Ciccio et al. (2016); Bhattacharya et al. (2014)

⁶¹³ Vgl. Owczarek, Janke (2018)

Mehrere Anwendungen dieses Clusters dienen der Erkennung von Anomalien an Materialien und Produkten anhand von vielfältigen Merkmalen. Dies gilt sowohl für deren initiale Charakterisierung⁶¹⁴ als auch für deren Detektion im Rahmen der Prozessausführung⁶¹⁵, wobei hierzu im Falle von optischen Merkmalen häufig Kamerasysteme zum Einsatz kommen. Außerdem werden auch zukünftige Fehler prognostiziert⁶¹⁶. Die Ermittlung der Normabweichungen findet sowohl für Teilprozesse des internen Materialflusses als auch in Bezug auf eine abschließende Qualitätsprüfung statt. Neben diesen material- und auftragspezifischen Betrachtungen existieren auch Anwendungen, welche die eingesetzten Ressourcen überwachen. Dies umfasst die Detektion eines fehlerhaften Verhaltens bis hin zu Ausfällen von Fertigungsanlagen⁶¹⁷, was auch als Condition Monitoring bezeichnet wird. Auch trifft dies auf die eingesetzten Betriebsmittel in den Logistikprozessen zu⁶¹⁸, z. B. zur Ermittlung von falsch-positiven RFID-Signalen bei der Identifikation von Materialien während der Beladung. Bei manuellen Prozessen werden durch den Einsatz zusätzlicher Sensoren, z. B. in Form von Smart Wearables, zudem die Bewegungen von Mitarbeitern, wie das Greifen in Behälter, überwacht und dabei eine Zuordnung in korrekte oder fehlerhafte Zustände vorgenommen⁶¹⁹. Anstelle individueller Ereignisse werden von einigen Anwendungen auch aggregierte Eigenschaften der genannten Bezugsobjekte bestimmt. Dies betrifft u. a. die Prognose der Qualität von Produkten und Maschinen⁶²⁰, um vorausschauend Nacharbeiten sowie Maßnahmen für die Instandhaltung einleiten zu können, was auch unter dem Begriff des Predictive Process Control zusammengefasst wird. In Bezug auf die eingesetzten Maschinen, z. B. Fertigungsanlagen sowie Lager- und Fördertechnik, wird zudem die Leistung ermittelt⁶²¹, um u. a. Aussagen über die OEE zu treffen.

5.2.2.7 Supply Chain Risk und Performance Management

Die ML-Anwendungen des Clusters des Supply Chain Risk und Performance Managements (SCRM und SCPM) dienen Überwachungsaufgaben zur Zustandsermittlung von Lieferketten, wobei diese entweder in ihrer Gesamtheit oder in Bezug auf einzelne Prozesse oder Akteure betrachtet werden. Ziel des Einsatzes von ML ist es, mehr Informationen über die oft intransparenten Prozesse außerhalb des jeweiligen Unternehmens oder Standortes zu erhalten, um die Effizienz und Robustheit der Lieferketten zu erhöhen. In Abgrenzung zum vorherigen Cluster besteht bei den meisten Anwendungen kein Bezug zu spezifischen Aufträgen, sodass auf Grundlage der bereitgestellten Informationen auch keine unmittelbare Einflussnahme angestrebt wird, sondern vielmehr eine Initiierung längerfristiger Anpassungsmaßnahmen. Neben einer häufig noch manuellen Ausführung werden teilweise in der Praxis auch konventionelle

⁶¹⁴ Vgl. Wang et al. (2017b)

⁶¹⁵ Vgl. Joshi et al. (2020)

⁶¹⁶ Vgl. Carvajal Soto et al. (2019)

⁶¹⁷ Vgl. Wen et al. (2019)

⁶¹⁸ Vgl. Ma et al. (2018)

⁶¹⁹ Vgl. Kucukoglu et al. (2018)

⁶²⁰ Vgl. Wang et al. (2012)

⁶²¹ Vgl. Singh et al. (2012)

Entscheidungstechniken eingesetzt, v. a. in Form von BI-Systemen, welche jedoch nur deskriptive Informationen unter Anwendung klassischer statistischer Verfahren berücksichtigen. Mehrere Anwendungen dieses Clusters dienen der Detektion von prozess- und akteursübergreifenden Störungen bzw. Risiken, einschließlich einer Ermittlung relevanter Kernursachen. Dies erfolgt sowohl im Rahmen einer Gegenwartsbetrachtung zur Charakterisierung dieser negativen Einflüsse, u. a. für die Wirtschaftlichkeitsbetrachtung von Lieferketten⁶²², als auch mittels Prognosen zu deren Antizipation. Letzteres umfasst u. a. die Bestimmung von Risiken für die Verspätung von Lieferungen⁶²³. Mehrere Anwendungen fokussieren dabei auch spezifische Risikoarten, wie Naturkatastrophen, Streiks und Terroranschläge⁶²⁴. Auch werden Betrugsfälle in Netzwerken⁶²⁵ und Cyber-Attacks⁶²⁶ betrachtet, um die Sicherheit von Lieferketten zu erhöhen. Anstelle dieser übergreifenden Betrachtung werden bei einigen Anwendungen auch bestimmte Teilbereiche von Lieferketten fokussiert. Dies betrifft Anomalien in vertriebsseitigen Nachfrageströmen⁶²⁷ oder in bereits ausgelieferten Produkten durch eine Berücksichtigung von After-Sales-Informationen⁶²⁸. Neben Risiken werden von mehreren Anwendungen auch aggregierte Leistungseigenschaften von Lieferketten ermittelt, wie deren Zuverlässigkeit sowie deren Reaktions- und Anpassungsfähigkeit⁶²⁹, wobei dies ebenfalls sowohl mittels einer Analyse des gegenwärtigen Zustands als auch durch Prognosen erfolgt. Hierbei werden teilweise von den Systemen auch Informationen zu den Ursache-Wirkungs-Beziehungen der Einflussfaktoren bereitgestellt, damit die Nutzer gezielt Schwachstellen mitigieren können.

5.3 Bewertung und Interpretation des Anwendungsspektrums

Das zuvor identifizierte Anwendungsspektrum von ML wird in diesem Unterkapitel anhand mehrerer Betrachtungsebenen analysiert. Das umfasst eine Prüfung der bisherigen Abdeckung der Aktivitäten des Logistikmanagements, wozu eine Zuordnung der Typen zu den Referenzstrukturen aus Kapitel 2 für die Systematisierung von Entscheidungsprozessen erfolgt. Auch wird der Umsetzungsstand der Typen anhand der Anzahl der jeweils vorliegenden Anwendungen untersucht. Durch eine damit verbundene Kombination der beiden Typenarten werden Zusammenhänge zwischen der Problemlösungsfähigkeit und den adressierten Entscheidungsprozessen aufgedeckt. Unter Berücksichtigung der zukünftigen Entwicklungen aus Kapitel 4.4 erfolgt zudem eine Ermittlung geeigneter Erweiterungsmöglichkeiten des Anwendungsspektrums im Sinne eines zukünftigen Forschungsbedarfes. Zum Abschluss wird die Bedeutung der Anwendungsmöglichkeiten für die logistische Praxis untersucht.

⁶²² Vgl. Ye et al. (2015)

⁶²³ Vgl. Baryannis et al. (2019a)

⁶²⁴ Vgl. Liu et al. (2016)

⁶²⁵ Vgl. Zage et al. (2013)

⁶²⁶ Vgl. Hiromoto et al. (2017)

⁶²⁷ Vgl. Tran et al. (2019)

⁶²⁸ Vgl. Ko et al. (2017)

⁶²⁹ Vgl. Lima-Junior, Carpinetti (2020)

5.3.1 Abdeckung der Referenzstrukturen für Entscheidungsprozesse

In Hinblick auf die in Kapitel 2.3.2 beschriebene Systematisierung der grundsätzlichen Aktivitäten innerhalb von Entscheidungsprozessen, welche von der Problemwahrnehmung bis zur Ausführung reichen, lässt sich eine hohe Abdeckung der identifizierten Problemlösungsfähigkeiten von ML-Anwendungen feststellen (siehe Abbildung 50). Demnach können alle Aktivitäten **durch eine oder mehrere Fähigkeiten unterstützt bzw. ausgeführt** werden. Für die Phase der Problemformulierung umfasst dies zum einen die Möglichkeit der routinemäßigen Detektion von problematischen Zuständen und Ereignissen – sowohl im Rahmen einer Gegenwartsbetrachtung mittels Identifikationsanwendungen als auch für die Zukunft mittels Prognoseanwendungen. Zum anderen kann auch ein Suchprozess nach Problemen durch Anwendungen mit der Fähigkeit der Analyse und Bewertung initiiert werden. Für die Präzisierung der Problem- und Zielstellungen können die letztgenannten Anwendungen zudem relevante Hintergrundinformationen bereitstellen, z. B. in Form von Assoziationsregeln und Rankings. Auch können diese Aktivitäten durch Prognoseanwendungen unterstützt werden, indem dadurch Informationen zu zukünftigen Entwicklungen bereitgestellt werden. Für die Erforschung von Handlungsalternativen in Form einzelner Parameter oder ganzer Strategien können sowohl bestehende Lösungsmöglichkeiten durch Anwendungen mit der Fähigkeit der Analyse und Bewertung als auch neue, unkonventionelle Lösungswege durch Optimierungsanwendungen identifiziert, bewertet und ausgewählt werden. Für die Bewertung der Handlungsalternativen in Form der Ermittlung von deren Auswirkungen können zudem Prognoseanwendungen eingesetzt werden. Die Realisierung der Entscheidungen ist dagegen nicht Teil der identifizierten Problemlösungsfähigkeiten, sondern erfolgt durch zusätzliche Hardwarekomponenten für die Aktorik der ML-Anwendungen oder durch externe Systeme. Die sich an die Realisierung anschließende Kontrolle der Entscheidungen kann wiederum durch dieselben ML-Fähigkeiten, wie im Falle der initialen Problemformulierung, unterstützt bzw. ausgeführt werden.

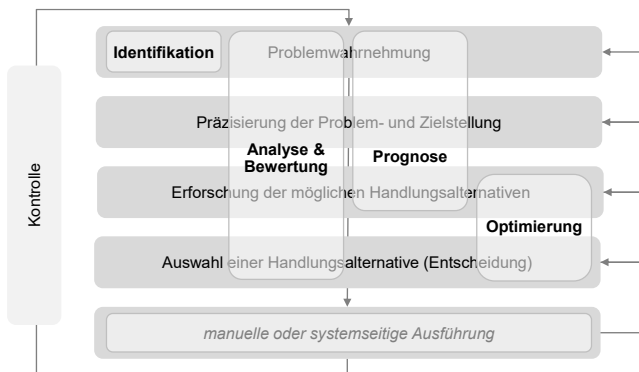


Abbildung 50: Typenbezogene Abdeckung der Aktivitäten von Entscheidungsprozessen⁶³⁰

⁶³⁰ Eigene Darstellung

Bei einer Betrachtung der Prozesse des Logistikmanagements, welche in Kapitel 2.2.2 zu Hauptaufgaben generalisiert wurden, lässt sich ebenfalls eine hohe Abdeckung der identifizierten Typen feststellen (siehe Abbildung 51). Demnach existieren bereits für alle logistischen Funktionen entsprechende ML-Anwendungen, wobei produktionslogistische Anwendungsfälle überwiegen. Zudem wird ersichtlich, dass neben reinen unternehmensinternen Anwendungsfällen auch mehrere Anwendungen existieren, die sich auf akteursübergreifende Problemstellungen beziehen. Ebenfalls sind alle drei betrachteten Aufgabenarten der Planung, Steuerung und Kontrolle abgedeckt. In Hinblick auf die damit verbundenen Planungshorizonte ist jedoch festzustellen, dass Anwendungen zu **strategischen Prozessen unterrepräsentiert** sind.

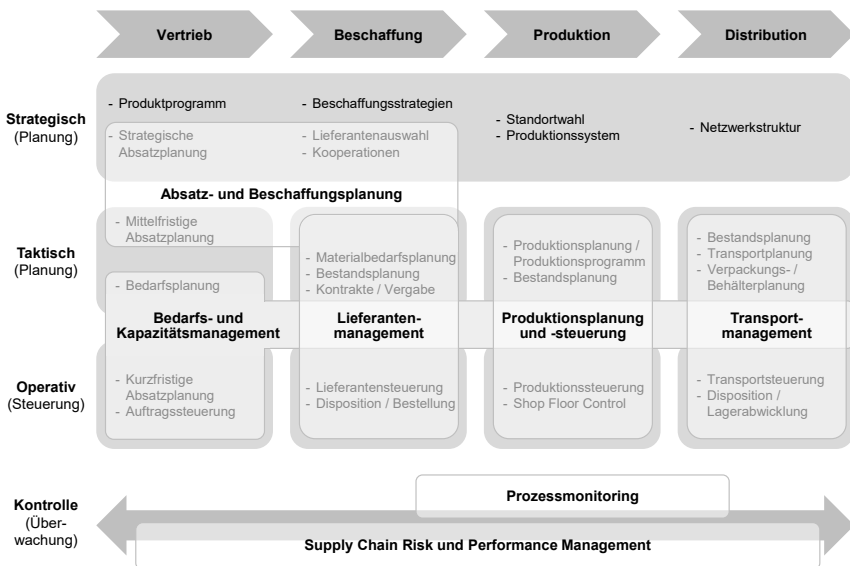


Abbildung 51: Typenbezogene Abdeckung von Prozessen des Logistikmanagements⁶³¹

Die bisherigen Anwendungsfälle für einen längerfristigen Planungshorizont sind zumeist den logistischen Funktionen des Vertriebes und der Beschaffung zuzuordnen. Sie sind Teil des Clusters **LAB**, wozu u. a. die Ermittlung der langfristigen Nachfrage und des Kundenverhaltens gehört. Ein weiterer Anwendungsfall mit einem vergleichsweise langen Planungshorizont betrifft die Netzplanung zur optimalen Gestaltung von Logistikstrukturen bestehend aus verschiedenen Lagerstandorten. Der Anwendungsfall der Nachfrageermittlung findet sich auch im **BKM** – jedoch hier für einen kürzeren Zeithorizont. Zusätzlich liegen in diesem Cluster Anwendungen zur Ermittlung der aktuellen, zukünftigen und optimalen Bedarfsmenge sowie der korrespondierenden Kapazität vor, u. a. um zentrale logistische Herausforderungen, wie den

⁶³¹ Eigene Darstellung

Bullwhip-Effekt, zu bewältigen. Diese Problemstellungen sind sowohl Teil der Vertriebsaufgaben als auch der weiteren drei Teilbereiche, sodass sich das Cluster des BKM entlang der gesamten Logistikkette erstreckt. Auch für die Beauftragung interner und/oder externer Wertschöpfungspartner auf Basis der Bedarfs- und Kapazitätsplanung existieren mehrere Anwendungen, die u. a. zur Ermittlung von Beschaffungskonzepten, zur Auswahl geeigneter Lieferanten sowie zur deren optimaler Einbindung beitragen und dem Cluster des **LM** zugeordnet sind. Für die sich anschließenden Prozesse der betrieblichen Leistungserstellung finden sich im Cluster der **PPS** mehrere Anwendungen. Diese umfassen vordergründig operative Planungs- und Steuerungsaufgaben, wie die Auftragsverteilung auf verschiedene Maschinen und Arbeitsstationen sowie die Bestimmung optimaler Maschinenparameter. Für die Distribution der Erzeugnisse und die innerbetrieblichen Materialbewegungen existieren ebenfalls Anwendungen, welche Teil des Clusters des **TM** sind und bedeutende Probleme der Logistik lösen. Neben Transportprozessen decken diese auch damit verbundene vor- und nachgelagerte Prozesse ab, z. B. zur Verpackung von Materialien. Für die logistischen Kontrollaufgaben lassen sich zwei zentrale Anwendungsbereiche festmachen. Zum einen existieren Anwendungen, welche unternehmensinterne Prozesse überwachen und analysieren. Diese sind Teil des Clusters des **PM**. Zum anderen dienen weitere Anwendungen der Bestimmung von Leistungs- und Qualitätsparametern entlang der Lieferkette, d. h. über Standort- und Unternehmensgrenzen hinweg, welche zum Cluster des **SCRM und SCPM** gehören. Bei den Anwendungen beider Überwachungscluster werden sowohl Einzelereignisse und Einflüsse, wie Störungen oder Risiken, als auch aggregierte Eigenschaften der Bezugsobjekte ermittelt.

Bei einer indikativen Zuordnung der am häufigsten umgesetzten Anwendungsfälle zur gewählten logistischen Referenzstruktur ergibt sich das in Abbildung 52 dargestellte Anwendungsspektrum. Hierbei wurde eine Generalisierung von problemspezifischen Merkmalen der Anwendungsfälle vorgenommen. Anhand der technischen Merkmale der jeweiligen ML-Anwendungen war jedoch festzustellen, dass – auch nur leichte – prozessseitige Unterschiede zu einer **abweichenden entwicklungsseitigen Gestaltung** führen, da u. a. andere Variablen und Lernverfahren zu berücksichtigen sind. Dies trifft bspw. auf die verschiedenen Szenarien der Produktionssteuerung in Form von Job Shop, Flow Shop und Open Shop zu. Aber auch die unterschiedlichen Zeithorizonte bei Planungsaufgaben erfordern individuelle technische Lösungen, was sich z. B. im Falle von Anwendungen für eine kurz- oder langfristige Nachfrageprognose zeigt. Selbiges gilt für unterschiedliche Bezugsobjekte, z. B. im Falle der Ermittlung von Störungen bei Maschinen oder Betriebsmitteln.

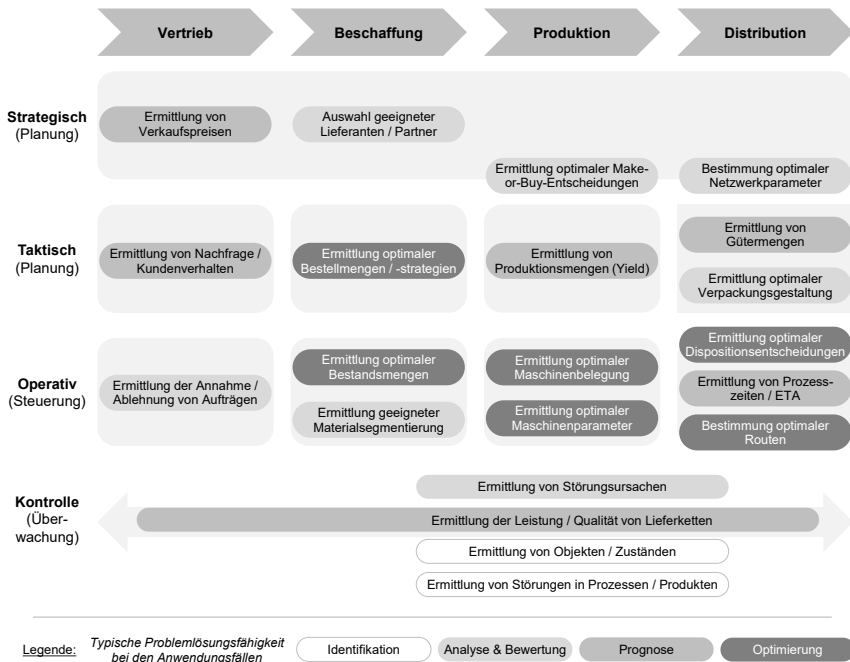


Abbildung 52: Anwendungsspektrum von ML-Anwendungen im Logistikmanagement⁶³²

5.3.2 Umsetzungsstand und Zusammenhänge zwischen den Typen

Für den Umsetzungsstand der identifizierten Typen, welcher sich auf die Häufigkeit der korrespondierenden ML-Anwendungen im Betrachtungszeitraum der durchgeführten Literaturanalyse von 2012 bis 2020 bezieht, lässt sich bei beiden Typenarten – bis auf **jeweils einen Ausreißer** – eine tendenziell homogene Verteilung feststellen. Bei dem Ausreißer im Falle der typisierten Problemlösungsfähigkeiten handelt es sich um die Prognose, welche bei ca. 70 % aller Anwendungen vorzufinden ist. In Bezug auf die typisierten logistischen Anwendungsbereiche sind ca. ein Viertel aller Anwendungen einer Problemstellung aus der PPS zuzuordnen. Eine Darstellung der relativen Häufigkeit der einzelnen Typen in Bezug auf die Gesamtanzahl der 115 ML-Anwendungen findet sich in der Ergebnisspalte bzw. -zeile der Tabelle 15.

⁶³² Eigene Darstellung. Es handelt sich um die häufigsten Anwendungsfälle mit den dafür typischen Problemlösungsfähigkeiten, wobei keine Differenzierung nach prozessindividuellen Merkmalen vorgenommen wurde.

Typenbezeichnungen	Identifikation	Analyse und Bewertung	Prognose I+II	Optimierung	
Langfristige Beschaffungs- und Absatzplanung		+	10 %	+	10 %
Bedarfs- und Kapazitätsmanagement		1 %	15 %	+	16 %
Lieferantenmanagement	+	3 %	10 %	3 %	16 %
Produktionsplanung und -steuerung	2 %	3 %	12 %	10 %	27 %
Transportmanagement	1 %	+	10 %	1 %	11 %
Prozessmonitoring	4 %	+	7 %		11 %
Supply Chain Risk und Performance Management	+	3 %	5 %		9 %
	7 %	10 %	69 %	15 %	n=115

Legende: + = geeignete Kombination für weitere Anwendungsfälle

Tabelle 15: Relative Häufigkeit der Typen

Sowohl die genannten Ausreißer als auch die weiteren Unterschiede in Bezug auf den Umsetzungsstand der einzelnen Typen lassen sich auf mehrere teilweise in Wechselwirkung stehende Ursachen zurückzuführen. Zum einen ist der **Forschungsstand zu den einzelnen Lernverfahren** – welche eine zentrale Grundlage für die Problemlösungsfähigkeiten darstellen – unterschiedlich weit fortgeschritten. Dies zeigt sich insbesondere bei einem Vergleich der Lernverfahren des SL mit denen des USL und RL, wobei letztere einen vergleichsweise geringeren Stand in Bezug auf die anwendungsorientierte Forschung aufweisen. Dies führt u. a. zur Unterrepräsentation von Optimierungs- gegenüber Prognoseanwendungen. Darüber hinaus bestehen auch **Unterschiede bei den verfügbaren Daten** in einzelnen Anwendungsbereichen der Logistik, welche die Anwendbarkeit von ML beeinflussen. Demnach liegen im Bereich der PPS bereits vergleichsweise viele Daten vor, u. a. in Form von Sensordaten zu Maschinen- bzw. Prozesszuständen und in Form von Planungs- bzw. Auftragsdaten aus PPS-Systemen. Davon abweichende Voraussetzungen sind für unternehmensübergreifende Problemstellungen aus dem TM sowie dem SCRM und SCPM festzustellen, bei denen ein Zugang zu den benötigten Daten häufig eingeschränkt ist, was zu einer geringeren Anzahl an Anwendungen führt. Auch werden viele Planungs- und Steuerungsaktivitäten sowie die Kommunikationsprozesse im Transport noch **manuell durchgeführt**, sodass grundlegend weniger Daten als bei produktionsnahen Prozessen verfügbar sind. Selbiges gilt für die oft manuell durchgeführten taktisch-strategischen Prozesse der LAB.

Eine weitere wichtige Ursache stellt die **Bedeutung der Anwendungsbereiche** für die Praxis dar, was große Auswirkungen auf die „Nachfrage“ der Industrie und dementsprechend auch

auf die Finanzierung von Forschungsaktivitäten hat. Bei öffentlich finanzierten Forschungsprogrammen im Kontext von ML bzw. KI lassen sich allgemein eher industrieseitige Forschungsschwerpunkte erkennen, was wiederum eine Erklärung der Dominanz von Veröffentlichungen und damit von Anwendungen in der PPS darstellt. Zusätzlich ist auch eine mögliche methodische Ursache anzuführen, die im Zusammenhang mit der in der vorliegenden Arbeit durchgeführten Literaturanalyse und dem dabei genutzten **Suchstring** steht. Demnach wurden Veröffentlichungen, die keine Abdeckung eines der im String enthaltenen Wörter aufweisen, nicht berücksichtigt. Allerdings ist auch denkbar, dass Veröffentlichungen bzw. darin enthaltene Anwendungsfälle keinen dieser Suchbegriffe enthalten, obwohl sie relevant für die vorliegende Untersuchung sind. Dies begründet sich u. a. mit einem abweichenden Verständnis der jeweiligen Autoren zur Logistik oder zu ML und wird insbesondere für Anwendungen zur Realisierung von Computer Vision angenommen. Diese werden mitunter auch primär dem Qualitätsmanagement zugeordnet, sodass in den Veröffentlichungen entsprechende Bezüge zur Logistik fehlen, was letztendlich zu der vergleichsweise geringen Anzahl von Identifikationsanwendungen führt.

Die einzelnen ML-Anwendungen sind eindeutig jeweils einer Ausprägung der beiden Typenarten zugeordnet. Für die resultierenden Tupel ist die relative Häufigkeit ebenfalls in Tabelle 15 dargestellt. Anhand dessen lässt sich feststellen, dass in den einzelnen logistischen Anwendungsbereichen die Ausprägungen und die Intensität der umgesetzten Problemlösungsfähigkeiten stark variieren. In **allen Bereichen werden bereits Prognoseanwendungen** umgesetzt, wobei diese Fähigkeit bei Problemstellungen mit einer hohen Abhängigkeit von externen Einflüssen besonders stark ausgeprägt ist. Dies gilt zuvorderst für den Bereich der LBA, in dem sich bisher ausschließlich Prognoseanwendungen finden, wobei Anwendungsfälle zur Nachfrageprognose (Demand Forecasting) dominieren. Beim BKM wird diese Fähigkeit zur Ermittlung zukünftiger Bedarfs- bzw. Bestellmengen genutzt. In Falle des TM finden sich Prognosen u. a. zur Ermittlung der erwarteten Prozess- bzw. Ankunftszeiten in Form der ETA.

Für die Bestimmung geeigneter Dispositionsentscheidungen und das Routing finden sich im TM darüber hinaus vereinzelt Optimierungsanwendungen. Auch für den ebenfalls deutlich prognosedominierten Bereich des LM ist eine Abdeckung von Anwendungen mit anderen Fähigkeiten in Form der Optimierung sowie der Analyse und Bewertung festzustellen. Beide Fähigkeiten werden hierbei insbesondere zur Auswahl geeigneter Lieferanten eingesetzt (Supplier Selection). Für den PPS-Bereich ergibt sich ein annähernd gleicher Anteil für Prognose- und Optimierungsanwendungen. Während erstere u. a. zur Prognose der Durchlaufzeit eingesetzt werden, dienen zweitens der Ermittlung optimaler Maschinenbelegungen bzw. Auftragsreihenfolgen. In Bezug auf die Optimierungsfähigkeit zeigt sich, dass diese bisher neben einem vergleichsweise häufigen Auftreten im PPS-Bereich nur in den genannten Bereichen des TM und LM realisiert wird. Insgesamt handelt es sich bei den bisherigen **Optimierungsanwendungen zumeist um operative Probleme**.

In den beiden Bereichen zur Überwachung in Form des PM sowie des SCRM und SCPM liegen neben Prognoseanwendungen vergleichsweise viele Anwendungen mit den Fähigkeiten der Analyse und Bewertungen sowie der Identifikation vor. Diese adressieren insbesondere Probleme zur initialen oder kontinuierlichen Ermittlung von Störungen und Risiken in internen Prozessen sowie entlang gesamter Lieferketten – sowohl in Echtzeit (Condition Monitoring) als auch für zukünftige Ausprägungen (Predictive Process Control). Auch eine Detektion von Objekten mittels Identifikationsanwendungen gehört zu den dominierenden Anwendungen des PM-Bereiches.

5.3.3 Zukünftige Erweiterungsmöglichkeiten

Während Prognoseanwendungen bereits in allen identifizierten Anwendungsbereichen eingesetzt werden, finden sich Anwendungen mit der Fähigkeit der Analyse und Bewertung in nur vier Bereichen. Im Falle der Identifikation und Optimierung sind es jeweils drei. Dies führt dazu, dass mehr als ein Drittel der 28 theoretischen Kombinationsmöglichkeiten bisher nicht durch Anwendungen abgedeckt sind. Während einige dieser „White Spots“ gewissermaßen inhärent sind⁶³³, stellen einzelne Tupel potenziell geeignete **Ansatzpunkte für die Erweiterung des Anwendungsspektrums** dar. Diese sind in Tabelle 15 mit einem „+“ gekennzeichnet. Zusätzliche Erweiterungsmöglichkeiten lassen sich unter Berücksichtigung der identifizierten Trends zu ML aus Kapitel 4.4.1 ableiten.⁶³⁴ Als ein zentraler Wegbereiter fungiert hierbei die Verbesserung der **praktischen Anwendbarkeit von Lernverfahren** des Reinforcement und des Unsupervised Learning, welche für alle bisher unterrepräsentierten Problemlösungsfähigkeiten eine wichtige technische Grundlage darstellen. Auch die Intensivierung der Forschungsaktivitäten zur **Nutzung von kleineren Datenmengen**, v. a. in Form des Transfer Learning und der Generative Adversarial Networks, spielen für das zukünftige Anwendungsspektrum eine bedeutende Rolle, da somit auch Anwendungen für logistische Problemstellungen mit einer eingeschränkten Datenverfügbarkeit realisierbar sind.

Ein zukünftiger Forschungsbedarf wird vor diesem Hintergrund in der Umsetzung von Optimierungsanwendungen für Entscheidungsprozesse mit mittel- bis langfristigen Planungshorizonten gesehen, zu denen entsprechend der aktuellen Datensituation bisher nur wenige Anwendungen mit dieser Fähigkeit existieren. Durch eine Nutzung der vielversprechenden Verfahren aus dem RL und EvL sind Anwendungsfälle zur Optimierung der **strategischen Netzplanung** im Rahmen der bisher eher operativ geprägten Bereiche der PPS und des TM, d. h. von Produktions- und Lagerstandorten, zu prüfen. Über die standortbezogene Allokation von Kapazitäten hinaus, welche Gegenstand bisheriger Anwendungen ist, sollte dies auch die Optimierung der Anzahl von Lager- und Produktionsstandorten sowie deren räumliche Anordnung

⁶³³ Ein Beispiel stellt der Bereich des Prozessmonitorings dar, dessen Überwachungsaufgaben keine Eignung für die Optimierungsfähigkeit aufweisen.

⁶³⁴ Es ist nicht auszuschließen, dass – trotz der Sorgfalt bei der durchgeführten Literaturanalyse – einige der genannten Anwendungsfälle bereits in der Forschung umgesetzt wurden.

umfassen. Für die PPS sind ebenfalls längerfristige Aufgaben zur **Gestaltung des Produktionssystems** durch entsprechende Optimierungsanwendungen abzudecken, u. a. in Form der Ermittlung einer passenden Organisationsform und des optimalen Produktionsprogramms, sowie zur Auswahl **strategischer Make-or-buy-Entscheidungen** auf Produktebene. Auch für die Prozesse der LBA sind weitere strategische Anwendungsfälle zur Optimierung der langfristigen Beschaffungsstrategien und des Produktprogramms zu realisieren. Ebenfalls ist eine **Harmonisierung der vertriebs- und produktionsseitigen Ziele** und Restriktionen im Sinne einer Optimierung des S&OP-Prozesses anzustreben, wobei dies sowohl für lang- als auch für kurzfristige Planungszeiträume zu realisieren ist. Weitere relevante Anwendungsfälle für Optimierungsanwendungen bestehen für **Problemstellungen der Lagerlogistik**, u. a. zur Ermittlung optimaler Bestandshöhen, Lagerplätze und Kommissionierreihenfolgen. Für diesen Bereich existieren bisher vordergründig Anwendungen zu ausführenden Prozessen, welche nicht Gegenstand der vorliegenden Untersuchung sind.

Hinsichtlich der weiteren Problemlösungsfähigkeiten sind Anwendungen zur Prognose von Entwicklungen für Lieferketten und Transportnetzwerken umzusetzen, welche in einem **mittel- bis langfristigen Horizont relevante Risiken** aufzeigen. Bisherige Anwendungen beschränken sich dabei zumeist auf eine Kurzzeitbetrachtung. Weitere Anwendungen sollten mittels der Fähigkeit der Analyse und Bewertung den Einfluss bestimmter Merkmale auf die langfristige Nachfrage bestimmen. Neben einer gezielten Beeinflussung durch den Entscheidungsträger können diese Informationen auch systemseitig im Kontext der zuvor genannten Optimierungsanwendungen genutzt werden, z. B. für die strategische Netzplanung. Insgesamt sind unter Nutzung zukünftiger Möglichkeiten zum verbesserten Umgang mit kleineren Datenmengen – neben der Ausweitung des Planungshorizontes – auch bewusst Anwendungen für **unternehmensübergreifende Prozesse** zu forcieren.

5.3.4 Bedeutung für die Praxis

Anhand einer Bewertung der identifizierten Typen durch die befragten Unternehmen im Rahmen der empirischen Untersuchung ist festzustellen, dass alle vier Problemlösungsfähigkeiten eine hohe bis sehr hohe Bedeutung für die Logistik aufweisen (siehe Abbildung 53). Für die Prognosefähigkeit zeigt sich dabei die höchste Bewertung (4,5). Das Vorliegen **valider Informationen zu zukünftigen Ausprägungen** von logistischen Planungsparametern und Handlungsalternativen nimmt für die Unternehmen einen hohen Stellenwert ein, da viele dieser Parameter vom Verhalten Dritter beeinflusst werden, wodurch sie einer hohen Unsicherheit unterliegen. Aufgrund der Querschnittsfunktion der Logistik bestehen dabei vergleichsweise viele Schnittstellen zu anderen Prozessen und Bereichen, wozu auch oftmals unternehmensübergreifende Akteure zählen. Die hohe Bedeutung von Prognosen hat in der Vergangenheit bereits zur Herausbildung verschiedener Entscheidungstechniken für die Unterstützung von logistischen Problemstellungen geführt, wobei zumeist klassische statistische oder modellge-

stützte Verfahren zum Einsatz kommen. Deren Fähigkeiten sind jedoch in vielen Anwendungsfällen technische Grenzen gesetzt, insbesondere im Falle dynamischer Umweltsituationen. Die Möglichkeit von ML zum kontinuierlichen Erwerb von neuem Wissen und dem daraus resultierenden Umgang mit diesen Problemen wird daher mit einem großen Potenzial assoziiert.




Abbildung 53: Bedeutung der Problemlösungsfähigkeiten von ML⁶³⁵

An zweiter Position der Bewertung befindet sich die Identifikationsfähigkeit (4,3), welche eine Ermittlung von vordefinierten Objekten, Aktivitäten und Zuständen umfasst. Damit steht sie häufig am Beginn von Entscheidungsprozessen zur Wahrnehmung einer Problemstellung bei einer routinemäßigen Überprüfung, z. B. bei der Erreichung bestimmter Zustände und Ereignisse. Die bisherigen Identifikationsanwendungen ermöglichen in diesem Zusammenhang eine permanente Detektion von Problemen in Echtzeit, was ein **frühzeitiges und zielgerichtetes Eingreifen** erlaubt und eine hohe Bedeutung für die Unternehmen einnimmt. Für solche routinemäßigen Überwachungen existieren auch bereits andere datenbasierte Verfahren bzw. darauf basierende IT-Systeme, z. B. in Form der statistischen Prozesskontrolle. Jedoch sehen die befragten Unternehmen auch hier große Vorteile von ML, die sich zum einen auf die Verarbeitung von vielen, sehr identischen Merkmalen beziehen, um z. B. Oberflächenfehler an Materialien zu detektieren. Zum anderen betrifft dies erneut die Lernfähigkeit, welche auch eine Identifikation von bisher unbekanntem Objekten bzw. Merkmalen ermöglicht.

Mit einer etwas geringeren Bedeutung (4,1) wird die Fähigkeit der Analyse und Bewertung zur Erkennung von verborgenen Zusammenhängen bewertet. Das Verständnis von Zusammenhängen zu Problemen und Ereignissen stellt für die Unternehmen eine wichtige Voraussetzung zur gezielten Beeinflussung dar. Die oftmals hohe Informationsvielfalt zur Aufdeckung dieser Zusammenhänge ist für Menschen jedoch nur eingeschränkt oder mit großem Aufwand realisierbar. Selbiges trifft laut der befragten Unternehmen auf die bestehenden Entscheidungstechniken zu. Mit dem Einsatz von ML-Anwendungen und der damit verbundenen **Möglichkeit zur Verarbeitung dieser Informationskomplexität** werden daher hohe Potenziale assoziiert. Auch die systemseitige Ausgabe von Hintergrundinformationen, z. B. in Form von Rankings der Features, wird hierbei als bedeutsam angesehen.

⁶³⁵ Eigene Darstellung

Die vergleichsweise geringste, aber – absolut betrachtet – weiterhin hohe Bedeutung (3,6) wird der Optimierungsfähigkeit beigemessen. Die Bestimmung optimaler Parameter und Strategien stellt bei vielen logistischen Problemen eine große Herausforderung dar, da entsprechend der integrativen Funktion der Logistik verschiedene Zielgrößen und Restriktionen zu berücksichtigen sind, die oft konfliktär zueinanderstehen. Diese Komplexität hat bei den bisher eingesetzten Techniken dazu geführt, dass viele Probleme als deterministische Entscheidungssituationen modelliert oder mittels Heuristiken gelöst werden, was jedoch deren praktische Anwendungsmöglichkeiten einschränkt. Im Einsatz von ML, insbesondere durch Nutzung des Reinforcement Learning, wird ein hohes Potenzial zur **Begegnung dieser Problemkomplexität** gesehen. Jedoch lässt sich aufgrund der geringeren Anzahl von entsprechenden Anwendungen abseits der Forschung auch noch eine höhere Unsicherheit in Bezug auf die Realisierbarkeit beobachten, was sich in dem Bedeutungsunterschied zu den anderen drei Fähigkeiten äußert.

Analog zu den Problemlösungsfähigkeiten weisen auch die sieben logistischen Anwendungsbereiche von ML durchweg eine hohe Bedeutung auf. Die Bewertungen reichen dabei von 3,8 bis 4,4 und sind in Abbildung 54 dargestellt. Die höchste Bedeutung ist für ML-Anwendungen des BKM festzustellen (4,4), was damit begründet wird, dass sich die Unternehmen in den dazugehörigen Prozessen mit **vielen Entscheidungsparametern** konfrontiert sehen, deren Ausprägungen zudem einer hohen Unsicherheit unterliegen, da sie vom Verhalten Dritter abhängig sind, z. B. in Form der jeweiligen Kunden und Lieferanten. Diese **Unsicherheit** gegenüber unternehmensexternen Vorgängen und Ereignissen wird auch als wichtiger Grund für die hohe Bedeutung der Anwendungen des TM angeführt (4,3). Neben der Abhängigkeit von externen Instanzen weisen die Problemstellungen dieses Bereiches – aufgrund einer vergleichsweise geringen Digitalisierung der Prozesse – auch eine eher **eingeschränkte Informationsverfügbarkeit** auf. Dasselbe Bewertungsniveau findet sich auch für die beiden Anwendungsbereiche zur Überwachung von logistischen Prozessen in Form des PM sowie des SCRM bzw. SCPM. Mit diesen Anwendungsfällen werden bedeutende Möglichkeiten zur Bereitstellung von Informationen für innerbetriebliche Prozesse und Logistikketten assoziiert, welche aktuell oft noch von einer **hohen Intransparenz** geprägt sind. Über die bestehende deskriptive Ebene hinaus umfasst dies auch die Detektion bisher unbekannter Störungen, die Ermittlung neuer Leistungsparameter sowie die Bereitstellung von Informationen zu zukünftigen Entwicklungen. Die etwas geringere Bedeutung von Anwendungen in der PPS wird mit der bereits umfassenden **Abdeckung durch konventionelle Entscheidungstechniken** und der vergleichsweise hohen Informationstransparenz begründet. Gerade in einem Einsatz von Optimierungsanwendungen zur Ermittlung von geeigneten Prozessparametern und Produktionsplänen in komplexen Entscheidungssituationen wird aber auch für diesen Bereich ein großes Potenzial gesehen. Anwendungen für die langfristige Absatz- und Beschaffungsplanung weisen die vergleichsweise geringste Bedeutung auf, was v. a. mit der **hohen Individualität** und der damit

einhergehenden eingeschränkten Datenlage begründet wird. Zudem werden aber auch technologieübergreifende **Hemmnisse zur Übergabe von strategischen Entscheidungen** an technische Systeme genannt.




Abbildung 54: Bedeutung der logistischen Anwendungsbereiche von ML⁶³⁶

5.4 Auswirkungen auf logistische Entscheidungsprozesse

Sowohl die in diesem Kapitel berücksichtigten Anwendungsfälle aus der Forschung als auch die bereits in der Praxis umgesetzten Anwendungen zeigen, dass der Einsatz von ML im Logistikmanagement mit verschiedenen positiven und negativen Auswirkungen für die Unternehmen einhergeht. Diese werden im vorliegenden Unterkapitel erläutert, wobei eine Differenzierung in direkte Wirkungszusammenhänge sowie in resultierende Nutzenpotenziale und Risiken vorgenommen wird.

5.4.1 Wirkungsdimensionen

Für die unmittelbar aus dem Einsatz von ML-Anwendungen resultierenden Veränderungen bei der Ausführung von logistischen Planungs-, Steuerungs- und Überwachungsaktivitäten lassen sich verschiedene Ausprägungen beobachten, die zur Systematisierung in **sechs zentrale Wirkungsdimensionen** zusammengefasst wurden (siehe Abbildung 55). Die einzelnen Dimensionen werden in den nachfolgenden Abschnitten – unter Bezugnahme auf die Anwendungsfälle der **Fallstudienforschung** aus Kapitel 4.3 – beschrieben.

⁶³⁶ Eigene Darstellung



Abbildung 55: Wirkungsdimensionen von ML im Logistikmanagement⁶³⁷

5.4.1.1 Transparenzerhöhung

Die bisherigen ML-Anwendungen im Logistikmanagement werden zumeist zur Entscheidungsunterstützung eingesetzt, indem sie auf Basis einer Integration und Verarbeitung von bestehenden Daten neue Informationen generieren, welche durch die Entscheidungsträger zur Lösung eines spezifischen Problems genutzt werden. Dabei wird keine beliebige Erhöhung der Informationsvielfalt für die Nutzer angestrebt, sondern vielmehr eine gezielte Bereitstellung von kontextbezogenen **Informationen mit einem betrieblichen Mehrwert**, d. h. eine „Datenveredlung“. Während die Funktion zur reinen Integration von unterschiedlichen Daten für eine Ableitung neuer Informationen auch bei anderen Entscheidungstechniken vorzufinden ist, zeichnen sich ML-Anwendungen zusätzlich durch die Verarbeitung, d. h. die Synthese, dieser Informationen aus. Demnach werden mittels der Lernverfahren tieferliegende Zusammenhänge und Muster zu den Anwendungsfällen aufgedeckt, die über eine deskriptive Analyse der bestehenden Techniken hinausgehen und durch den Menschen oft nur mit einem hohen Aufwand extrahierbar sind. Hierbei kann es sich zum einen um die **Verbesserung bestehender Informationen** handeln, wie im Anwendungsfall 1, bei dem die zukünftigen Materialbedarfe von der realisierten ML-Anwendung deutlich präziser als von den bisherigen Systemen ermittelt werden. Zum anderen können auch **neue Informationen generiert** werden, die bspw. aufgrund ihrer Komplexität bisher unberücksichtigt blieben. Dies trifft auf den Anwendungsfall 4 zu, bei dem auf Basis der Integration und Verarbeitung von verschiedenen – aus

⁶³⁷ Eigene Darstellung

logistischer Sicht bisher eher unbedeutenden – Datenquellen eine Risikobewertung von Lieferanten vorgenommen wird, welche bislang in dieser Form nicht verfügbar war. Diese Erweiterung des für die Ausführung von Entscheidungsprozessen verfügbaren Informationsspektrums wird unter der Wirkungsdimension der **Transparenzerhöhung** subsumiert.

5.4.1.2 Faktenbasierte Entscheidungen

Entsprechend des hohen Aufwands bei der Lösung komplexer Probleme, was neben der Ermittlung und Auswahl von Handlungsalternativen auch die dafür notwendige Informationsbeschaffung betrifft, neigen Entscheidungsträger in der Praxis – bewusst und unbewusst – zu **Vereinfachungen**. Dazu zählen u. a. eine selektive Auswahl von Informationen, eine Abstraktion der Probleme sowie eine Nutzung von Heuristiken für die Problemlösung. Gleichzeitig werden die damit verbundenen Aktivitäten in den Entscheidungsprozessen, z. B. die Bewertung von Variablen, Zielen und Handlungsalternativen, durch **subjektive Wahrnehmungen und Emotionen** beeinflusst, die in Verbindung mit den persönlichen Erfahrungen der jeweiligen Entscheidungsträger stehen. Dies führt dazu, dass in Entscheidungssituationen – anstelle logischer Schlussfolgerungen auf Basis der vorliegenden Informationen – häufig eine Orientierung nach dem „Bauchgefühl“, d. h. der Intuition der jeweiligen Personen erfolgt. In Verbindung mit einer geringen Entscheidungszeit sowie mit den beschränkten Speicher- und Rechenkapazitäten des menschlichen Gehirns äußert sich dies oft in nicht optimalen bzw. fehlerhaften Entscheidungen. Durch den Einsatz von ML-Anwendungen kann diesen menschlichen Einschränkungen begegnet werden. Zum einen basieren die systemseitigen Ergebnisse entsprechend des induktiven Funktionsprinzips von ML vollständig auf Daten, welche wiederum die bisherige betriebliche Realität repräsentieren. Eine Beeinflussung des erworbenen Wissens durch subjektive Faktoren, wie ein moralisches Bewusstsein oder Gefühle, findet entsprechend einer Zuordnung aller heutigen Systeme zur schwachen KI-Hypothese (siehe Kapitel 2.4.1.4) nicht statt. Zum anderen zeigen die bestehenden ML-Anwendungen aus Forschung und Praxis, dass diese bereits bessere Ergebnisse bei der Lösung komplexer Problemstellung, wie z. B. dem Dilemma der Auftragsplanung oder dem Traveling Salesman Problem, als menschliche Entscheidungsträger oder andere Entscheidungstechniken erzielen. Diese Fehlerreduktion sowie die angesprochene Objektivierung von Problemlösungen werden unter der Wirkungsdimension der **faktenbasierten Entscheidungen** zusammengefasst.

5.4.1.3 Antizipative Planung

Entsprechend der ermittelten Problemlösungsfähigkeiten sind ML-Anwendungen in der Lage, verlässliche Prognosen zur zukünftigen Ausprägung von Ereignissen und Zuständen sowie zu Auswirkungen von Handlungsalternativen – auch im Falle komplexer logistischer Probleme – zu erstellen. Das zeigt sich auch bei den bereits in der Praxis realisierten Systemen in Form der Anwendungsfälle 1 und 2. Durch die bereitgestellten Prognoseergebnisse wird das jeweils verfügbare Informationsspektrum in Entscheidungsprozessen – ausgehend von der bisher

vorherrschenden vergangenheits- und gegenwartsbezogenen Betrachtung – um ein zukunftsbezogenes Wissen erweitert, weshalb in Ergänzung zur ersten Wirkungsdimension auch von einer „**vorausschauenden**“ **Transparenz** gesprochen werden kann. Infolge der damit verbundenen Reduzierung der Unsicherheit für die Entscheidungsträger können logistische Systeme optimal und ohne unnötige Risikopuffer gestaltet werden. Im Zuge einer weiteren Verbesserung der Prognosequalität von ML-Anwendungen, die langfristig zur Realisierung von sog. „sicheren“ Prognosen führen könnte, ist es für Unternehmen zudem möglich, zukünftige Kundenaufträge vollständig zu antizipieren. Dies erlaubt eine bedarfsgerechte Initiierung der logistischen Leistungserstellung vor dem Eingang konkreter Bestellungen, z. B. die Distribution von Produkten zu potenziellen Kunden – ohne dass von diesen ein Auftrag vorliegt. Auch wäre eine vorausschauende Fertigung von prognostizierten Aufträgen möglich, sodass in Anlehnung an ein zentrales Produktionsprinzip von **Make-to-predicted-Order** gesprochen werden kann, was gewissermaßen eine Symbiose aus einer Pull- und Push-Steuerung darstellt. Diese veränderten Möglichkeiten zur zukunftsorientierten Ausführung von Entscheidungsprozessen werden mit der Wirkungsdimension der **antizipativen Planung** beschrieben.

5.4.1.4 Autonome Entscheidungen

Entsprechend ihres Einsatzes als Entscheidungstechnik dienen ML-Anwendungen der Automatisierung von Prozessen, d. h. der Übertragung von menschlichen Tätigkeiten an Systeme. Wie die Ausführungen in Kapitel 2.4.2.4 zeigen, unterscheidet sich das Funktionsprinzip von ML hierbei von den bisherigen modellbasierten Entscheidungstechniken, wie z. B. Expertensysteme oder RPA-Anwendungen, welche nur in der Lage sind, Probleme anhand der vom Menschen vorgegebenen Regeln zu lösen. Eine eigenständige Anpassung der Problemlösungsfähigkeiten ist durch diese Systeme nicht realisierbar, sodass deren Anwendungsmöglichkeiten für viele Entscheidungsprozesse in der Praxis, insbesondere im Falle einer ausgeprägten Dynamik, stark eingeschränkt sind. Demgegenüber können ML-Anwendungen – durch das Lernen auf Grundlage neuer Daten – ihr Wissen und damit auch ihr **Verhalten adaptiv anpassen**. Dies ermöglicht abseits der bisher vorherrschenden Unterstützungsfunktion eine Realisierung von semi- bis vollautonomen Systemen, welche mit geringen bzw. ohne jegliche Eingriffe des Menschen ausgeführt werden. Durch die Autonomisierung von mehreren miteinander in Verbindung stehenden Geschäftsprozessen ist es dabei auch möglich, ganze logistische Teilfunktionen systemseitig auszuführen, sodass selbststeuernde „Meta-Systeme“ entstehen. In Analogie zum autonomen Fahren wurde in diesem Zusammenhang von SAP der Begriff der **Self-driving Supply Chain** geprägt⁶³⁸, welcher ausgehend von einer prognostizierten Nachfrage die optimalen Bedarfe für alle logistischen Prozesse ermittelt und in geeignete Maßnahmen überführt, deren Auswirkungen in der Realität ebenfalls durch die Systeme wahrgenommen werden und im Sinne des Perception-Action-Cycle zu deren Anpassung führen.

⁶³⁸ Vgl. Klemm (2018), S. 26 f.

Diese Realisierung einer systemseitigen Ausführung von Entscheidungsprozessen wird unter der Wirkungsdimension der **autonomen Entscheidungen** zusammengefasst.

5.4.1.5 Dynamische Entscheidungen

Der hohe Aufwand bei der Lösung komplexer Probleme führt auch dazu, dass in der Praxis die entsprechenden Planungs-, Steuerungs- und Überwachungsaktivitäten nur in gewissen zeitlichen Abständen ausgeführt werden können. Durch den Einsatz von ML-Anwendungen kann dieser Aufwand und damit die benötigte **Zeit für die Ausführung von Entscheidungen deutlich reduziert** werden. Dies begründet sich sowohl mit einer schnelleren Beschaffung und Aufbereitung der benötigten Informationen, welche durch die Systeme automatisch bezogen werden, als auch mit einer performanteren Datenverarbeitung. Infolge dieser Beschleunigung ist es möglich, die Frequenz der Aktivitäten von Entscheidungsprozessen zu erhöhen, z. B. von einer täglichen auf eine stündliche bis hin zu einer permanenten Ausführung. Hierdurch können kontinuierlich Anpassungen an den logistischen Systemen zu deren bedarfsge-rechter Gestaltung vorgenommen werden. Dies zeigt sich z. B. im Anwendungsfall 1, bei dem mittels einer regelmäßigeren Aktualisierung der Prognose des erwarteten Bedarfs die Abstimmung zwischen Produktion und Vertrieb im Sinne des S&OP-Prozesses verbessert wird. Zudem wird dadurch auch die Latenz der Reaktion auf relevante Ereignisse für die Logistik deutlich reduziert. Ein Beispiel stellt der Anwendungsfall 4 dar, bei dem durch den Einsatz der ML-Anwendung kritische Störungen in der Lieferkette zeitnah nach deren Auftreten detektiert werden. Die Ablösung der bisher quasi-statischen Ausführung von Entscheidungsprozessen wird mit der Wirkungsdimension der **dynamischen Entscheidungen** beschrieben.

5.4.1.6 Ganzheitliche Planung

Die Komplexität von Entscheidungsprozessen steigt mit der Größe des jeweiligen Bezugssystems, u. a. durch die zunehmende Anzahl von Variablen, deren Beziehungen und den zu berücksichtigenden Zielgrößen. Vor diesem Hintergrund werden viele logistische Planungs-, Steuerungs- und Überwachungsaktivitäten nur für kleinere Bezugssysteme ausgeführt, z. B. für einzelne Aufträge, Produkte oder Standorte. Diese dezentralen Entscheidungen erlauben einerseits eine höhere Ergebnisqualität; sie führen aber andererseits oft zu „isolierten“ Betrachtungen, bei denen die Informationen aus anderen Teilsystemen, z. B. die Bedarfe und Ziele, nicht adäquat berücksichtigt werden. Entsprechend der Fähigkeit zum Umgang mit einer hohen Problemkomplexität kann mit dem Einsatz von ML-Anwendungen diese dezentrale und isolierte Ausführung von Entscheidungen zugunsten einer integrativen Betrachtung überwunden werden, was unter der Wirkungsdimension der **ganzheitlichen Planung** zusammengefasst wird. Als Beispiel hierfür ist der Anwendungsfall 3 zu nennen, bei dem die Bestände einer Produktart mittels der ML-Anwendung über mehrere Standorte und Stufen des logistischen Netzwerkes im Sinne eines Multi-Echelon-Ansatzes optimiert werden. Dies führt für die betrachteten Produkte zur einer Reduzierung des Bullwhip-Effekts in den betreffenden Lieferketten. Im Falle einer systemseitigen Bereitstellung entsprechender Informationen für weitere

Produktgruppen können darüber hinaus auch Optimierungen für größere Bezugssysteme vorgenommen werden, z. B. für die Standorte einzelner Länder oder für gesamte Wertschöpfungsnetzwerke, was letztendlich einen Übergang von einer dezentralen Einzelsteuerung hin zu einer **Netzwerksteuerung** darstellt. Neben dieser vertikalen wird auch eine horizontale Integration entlang der Wertschöpfungskette ermöglicht, indem vormals getrennte Prozesse und Funktionsbereiche durch die systemseitige Ausführung der entsprechenden Planungsaktivitäten integriert betrachtet werden. Als Beispiel ist die systemseitig unterstützte **Harmonisierung** der vertriebs- und produktionsseitigen Bedarfe für den S&OP-Prozess in Anwendungsfall 1 zu nennen.

5.4.2 Nutzenpotenziale

Durch die „Operationalisierung“ der genannten Wirkungsdimensionen in Form der Nutzung von ML-Anwendungen für die Lösung spezifischer Probleme lassen sich verschiedene betriebswirtschaftliche Nutzenpotenziale realisieren. Dies betrifft zuvorderst die Beschleunigung von betrieblichen Abläufen, u. a. durch die zeitliche Synchronisation von Prozessen und die Reduktion von Wartezeiten. In Verbindung mit der Verringerung des Aufwands für die Entscheidungsfindung resultiert das in einer **Reduzierung der Durchlaufzeiten** von Prozessen. Die Beschleunigung von Aufläufen zeigt sich auch in Bezug auf Störungen oder Anomalien, die entweder direkt nach dem Auftreten oder sogar vorausschauend detektiert werden können. Durch die Einleitung geeigneter Maßnahmen – deren Ermittlung ebenfalls durch ML-Anwendungen unterstützt werden kann – führt das zu einer **Verbesserung der Qualität** von Prozessen und Produkten. Gleichzeitig kann durch die Antizipation zukünftiger Ereignisse auch die **Robustheit** von logistischen Systemen erhöht werden. Hierbei ermöglichen die ML-Anwendungen – auch im Falle mehrstufiger, globaler Logistikketten – eine bedarfsgerechte Gestaltung, u. a. durch den Abbau von Risikopuffern, z. B. in Form von Sicherheitsbeständen, sowie eine Reduzierung von aufwändigen Ad-hoc-Maßnahmen. Dadurch können in vielen Fällen bedeutende **Kosteneinsparungen** erzielt werden.

Das Effizienzpotenzial von ML-Anwendungen bezieht sich auch auf die **Reduktion des Personalbedarfs** infolge der Automatisierung von Prozessen. Anstelle eines Abbaus von Arbeitsplätzen kann die Verringerung manueller Aufwände in den entsprechenden Prozessen aber auch für eine gezielte **Verbesserung der Arbeitsbedingungen** der Mitarbeiter genutzt werden, u. a. durch deren Entlastung sowie durch eine Aufwertung ihrer Rolle in Form der Übertragung neuer, höherwertiger Aufgaben. In Ergänzung zu dieser sozialen Dimension lassen sich auch Potenziale zur **Verbesserung der ökologischen Nachhaltigkeit** durch den Einsatz von ML-Anwendungen erzielen. Dies umfasst sowohl eine systemseitige Erhöhung der Transparenz über logistische Prozesse, z. B. in Form der Ermittlung von Kernursachen für Verschwendungen, als auch Prozessoptimierungen durch die Gestaltung entsprechender Anwendungen, z. B. für eine geeignete Bündelung von Transporten. Neben diesen primär prozess-

seitigen Auswirkungen ergeben sich auch verschiedene Nutzenpotenziale für die Positionierung im Wettbewerbsumfeld. Demnach kann die **Kundenzufriedenheit** durch eine höhere logistische Servicequalität, reduzierte Kosten und das Angebot neuer datenbasierten Services verbessert werden. Letzteres impliziert auch die Entwicklung von **Geschäftsmodellen** auf Grundlage der ML-Anwendungen. Gegenüber potenziellen Zielkunden und Partnern kann sich der Einsatz von ML zudem positiv in Form einer verbesserten **Außenwirkung** der Unternehmen mit Implikationen für zukünftige vertriebliche Aktivitäten auswirken.

Zur Ermittlung von etwaigen Bedeutungsunterschieden in der Praxis wurden verschiedene Potenziale im Rahmen der durchgeführten Onlinebefragung durch die Unternehmen bewertet. Aufgrund der – entsprechend des geringen Umsetzungsstands von produktiven Systemen – eingeschränkten Möglichkeiten vieler Teilnehmer zur Einschätzung des tatsächlich realisierten Nutzens bezog sich die Befragung auf die bedeutendsten Beweggründe für den Einsatz von ML-Anwendungen (siehe Abbildung 56). Als wichtigstes Potenzial bezeichnen die Unternehmen die Erhöhung der **Transparenz** (76 %), womit eine verbesserte Entscheidungsfindung assoziiert wird. Gleichzeitig lässt sich hieraus ein intendierter Einsatz der Anwendungen als Entscheidungsunterstützung ableiten. Die Möglichkeit zur **Automatisierung** von Entscheidungsprozessen stellt mit leichtem Abstand den zweitwichtigsten Beweggrund dar (71 %). Bei einer gruppenspezifischen Auswertung ist hierzu festzustellen, dass deutlich mehr erfolgreiche Unternehmen (83 %) und Industrieunternehmen (82 %) als Unternehmen des Branchendurchschnitts und Logistikdienstleister dieses Nutzenpotential als Beweggrund anführen. Der **Reduzierung von Kosten** durch den Einsatz von ML wird ebenfalls eine sehr hohe Bedeutung beigemessen (71 %), wobei dies im Falle der LDL noch stärker auffällt (82 %). In diesem Zusammenhang ist ebenfalls zu konstatieren, dass das Effizienzpotenzial von ML nicht alleine mit der Verringerung des Personalaufwands assoziiert wird. Letzteres wird demnach nur von knapp der Hälfte der Unternehmen als Beweggrund genannt (47 %). Weitere Effizienzsteigerungspotenziale werden von knapp zwei Drittel der Unternehmen in der Reduzierung der Durchlaufzeiten gesehen (62 %). Ähnlich bedeutsam ist die Steigerung der Qualität von Prozessen und Produkten (60 %), z. B. durch eine Detektion von Anomalien und Störungen. Die Nutzung von ML zur Erweiterung des Produkt- und Dienstleistungsportfolios stellt dagegen nur für knapp 47 % der Unternehmen einen Beweggrund dar. Die Potenziale mit der geringsten Bedeutung stehen in Verbindung mit der Aufwertung der Außenwahrnehmung der Unternehmen, gefolgt von einer Verbesserung der sozialen oder ökologischen Nachhaltigkeit, was nur von jedem vierten bis fünften Unternehmen genannt wurde (24 % bis 20 %). Für Letzteres zeigt sich allerdings im Falle der erfolgreichen Unternehmen eine etwas höhere Bedeutung (33 %).



Abbildung 56: Gründe für den Einsatz von ML im Logistikmanagement⁶³⁹

5.4.3 Risiken

Den genannten Nutzenpotenzialen stehen mehrere negative Auswirkungen gegenüber, die ebenfalls aus dem Einsatz von ML in logistischen Entscheidungsprozessen resultieren können. Ein bedeutendes Risiko stellt die unreflektierte Nutzung „falscher“ Entscheidungen dar – sowohl in Form von Einzelfällen als auch bei systematischen Abweichungen der Anwendungen in Form eines Bias. Hierbei kann es sich zum einen um Ergebnisse handeln, die faktisch eine geringe Genauigkeit aufweisen, da sie keine geeignete Problemlösung darstellen. Neben modellseitigen Unzulänglichkeiten sind diese Ergebnisse z. B. auf fehlerhafte Daten oder eine bewusste Manipulation zurückzuführen. Zum anderen umfasst dies auch faktisch korrekte Entscheidungen, die jedoch für die jeweiligen Problemstellungen aufgrund anderer Bewertungskriterien abseits der Genauigkeit unzulässig sind, z. B. weil sie von ethischen oder rechtlichen Standards abweichen. Bleiben diese Ergebnisse bis zu ihrer Ausführung unerkannt, können negative Effekte für die betroffenen Geschäftsprozesse bzw. die Unternehmen auftreten. Neben dieser Betrachtung des systemseitigen Outputs steht ein weiteres Risiko im Zusammenhang mit der etwaigen **Einbindung vertraulicher Informationen** über die Input-Daten der Systeme, z. B. in Form geschäftskritischer und personenbezogener Daten. In diesen Fällen wird das Risiko gesehen, dass unbefugte Personen Zugang zu diesen Daten erhalten.

⁶³⁹ Eigene Darstellung. Bei dieser Erhebung war eine Mehrfachnennung möglich.

Auch mit der Übernahme von bisher manuellen Aktivitäten durch ML-Anwendungen und der damit verbundenen Reduzierung des Aufgabenspektrums für die derzeitigen Entscheidungsträger wird ein hohes Risiko assoziiert. Dies kann – insbesondere bei semi- bis vollautonomen Szenarien – dazu führen, dass sich die Aufgaben der Mitarbeiter im Wesentlichen auf die Kontrolle von systemseitigen Entscheidungen beschränken. Auf lange Sicht kann dies zu einer deutlichen **Abnahme der Problemlösungsfähigkeiten** bei den Mitarbeitern führen, was übergreifend mit einem Wissensverlust für die Unternehmen gleichzusetzen ist. Auch kann die Veränderung des menschlichen Aufgabenspektrums zu einer wahrgenommenen Dominanz der Systeme aus Sicht der Nutzer führen, sodass diese sich auf die Rolle reiner Überwachungsorgane degradiert fühlen. Neben **negativen Auswirkungen auf die Akzeptanz** des Technologieeinsatzes kann dies zu einer Demotivation bei den Mitarbeitern führen, was sich wiederum negativ auf die Innovationskraft und Produktivität der Unternehmen auswirkt. Im Resultat besteht dadurch das nicht unerhebliche Risiko, dass die mittels des Einsatzes von ML-Anwendungen erzielten **Kosteneinsparungen langfristig überkompensiert** werden.

5.5 Synthese: Eignung von Anwendungsfällen

Im Kapitel 5 wurde das Anwendungsspektrum von ML im Logistikmanagement auf Grundlage des gegenwärtigen Forschungsstands herausgearbeitet und bewertet. Mithilfe der entwickelten Typologie konnte dabei die Komplexität der potenziell realisierbaren Anwendungsmöglichkeiten auf geeignete Weise reduziert werden. Unter Berücksichtigung von produktiven Anwendungen aus der Praxis wurden zudem unmittelbare Veränderungen des Einsatzes von ML für die Ausführung von logistischen Entscheidungsprozessen sowie daraus resultierende betriebswirtschaftliche Potenziale und Risiken ermittelt. Die Ergebnisse des Kapitels repräsentieren in ihrer Gesamtheit die für das vorliegende Untersuchungsfeld möglichen Ausprägungen der drei Dimensionen des verkürzten TPC-Modells, d. h. die technischen Funktionalitäten, Aufgaben und Auswirkungen. Diese Ausprägungen können als **Entscheidungsgrundlage zur Auswahl geeigneter Anwendungsfälle** im Logistikmanagement für den Einsatz von ML sowie für die damit verbundene Abwägung zwischen mehreren Entscheidungstechniken genutzt werden. Hierzu wurden die erzielten Ergebnisse zu einzelnen Kriterien synthetisiert, welche entsprechend der übergreifenden Technologie- und Prozessbetrachtung der Untersuchung als „**Eignungsindikatoren**“ zu interpretieren sind (siehe Abbildung 57).



Abbildung 57: Indikatoren für die Eignung von Anwendungsfällen zum Einsatz von ML⁶⁴⁰

⁶⁴⁰ Eigene Darstellung

In Bezug auf die realisierbaren technischen Funktionalitäten von ML existieren **vier zentrale Problemlösungsfähigkeiten**, welche zur Ausführung bzw. Unterstützung von verschiedenen Aktivitäten in Entscheidungsprozessen – beginnend bei der Wahrnehmung von Problemen bis zur Auswahl geeigneter Handlungsalternativen – eingesetzt werden können. Es ist festzustellen, dass diese Fähigkeiten für viele Prozesse entlang der logistischen Teilfunktionen und der zeitlichen Realisierungsebenen nutzbar sind, wobei entsprechend der häufig eingeschränkten Informationsverfügbarkeit strategische und unternehmensexterne Anwendungsfälle tendenziell schwieriger zu realisieren sind. In Hinblick auf die Merkmale der bisher adressierten Probleme wird ersichtlich, dass ML-Anwendungen auch für sehr **komplexe Entscheidungssituationen**, z. B. im Falle von vielen dynamischen Variablen und konfliktären Zielsetzungen, geeignete Lösungen bereitstellen können.

Durch den gezielten Einsatz von ML-Anwendungen für logistische Problemstellungen können mehrere Veränderungen für die Ausführung der Planungs-, Steuerungs- und Überwachungsaktivitäten erwirkt werden. Grundsätzlich werden die jeweiligen Entscheidungsträger zur zielgerichteten Detektion von Problemen sowie zur Ermittlung geeigneter Lösungen befähigt, sodass neben einer **Fehlerreduktion** bei Entscheidungen auch Mitarbeiter ohne größere Vorerfahrung für die entsprechenden Prozesse eingesetzt werden können. Über eine Entscheidungsunterstützung hinaus sind die Anwendungen entsprechend ihrer Lernfähigkeit auch zur **autonomen Ausführung von Entscheidungsprozessen** einsetzbar. Hieraus ergeben sich in Abhängigkeit des jeweiligen Anwendungsfalls mehrere Nutzenpotenziale, die von Effizienzsteigerungen in Form von Kosten- und Zeiteinsparungen über Verbesserungen der logistischen Servicequalität bis hin zur Verbesserung der ökologischen und sozialen Nachhaltigkeit reichen. Insbesondere aus der Autonomisierung können aber auch größere Risiken für die Unternehmen bei der Ausführung von Entscheidungsprozessen resultieren, die sich neben einer **Demotivation der Mitarbeiter** durch eine wahrgenommene Entmündigung auch auf die Abnahme der Produktivität und Innovationskraft der Unternehmen beziehen.

Trotz der ermittelten Stärken von ML im Vergleich zu einer manuellen Ausführung und zu anderen Entscheidungstechniken ist weiterhin von Problemstellungen im Logistikmanagement auszugehen, für deren Lösung ein Einsatz von ML-Anwendungen vergleichsweise weniger geeignet ist. Hierzu gehören insbesondere wohlstrukturierte Probleme bzw. deterministische Entscheidungssituationen, die mittels Regellogiken eindeutig lösbar sind, sodass modellgestützte Entscheidungstechniken eine hohe Eignung aufweisen, z. B. Expertensysteme und RPA. Darüber hinaus existieren auch Anwendungsfälle, die entsprechend ihrer Merkmale die in diesem Unterkapitel genannten Eignungsindikatoren erfüllen, jedoch aufgrund darüberhinausgehender **Voraussetzungen des adoptierenden Umfeldes** nicht für den Einsatz von ML geeignet sind. Diese Rahmenbedingungen, welche auch die Nutzerdimension mit einschließen, wurden aufgrund der in diesem Kapitel eingenommenen technisch-prozessualen Betrachtungsperspektive bewusst nicht berücksichtigt. Ihre Erhebung erfolgt separat im nachfolgenden Kapitel.

6 Anforderungen

In diesem Kapitel werden technologie- und domänenspezifische Voraussetzungen für einen erfolgreichen Einsatz von ML-Anwendungen im Logistikmanagement erarbeitet. Entsprechend der Erkenntnisse aus Kapitel 2.1.3 umfasst dies sowohl eine Betrachtung der Adoptionsobjekte als auch des adoptierenden Umfeldes. Für die nachfolgende Entwicklung geeigneter Maßnahmen wird zudem der gegenwärtige Umsetzungsstand der ermittelten Voraussetzungen in der Praxis analysiert. Dies soll insgesamt zur Beantwortung der vierten sekundären Forschungsfrage führen:

Welche Anforderungen bestehen an den erfolgreichen Einsatz von ML-Anwendungen im Logistikmanagement und wie ist deren Umsetzungsstand in der Praxis?

Ausgehend von einer Konkretisierung des gewählten **Forschungsdesigns** für die vorliegende Untersuchung orientiert sich die Struktur des restlichen Kapitels an mehreren Anforderungsgruppen, welche einleitend abgegrenzt werden (Kapitel 6.1). Nach den Anforderungen an die **Funktionen** (Kapitel 6.2) und **Qualitätseigenschaften** (Kapitel 6.3) von ML-Anwendungen werden anschließend die benötigten **Umfeldeigenschaften** (Kapitel 6.4) beschrieben. Zum Abschluss erfolgt eine quantitative Bewertung der identifizierten Eigenschaften, welche in deren Priorisierung für eine Berücksichtigung bei der Entwicklung von Umsetzungsmaßnahmen mündet (Kapitel 6.5).

6.1 Forschungsdesign und Taxonomie der Anforderungen

In Ermangelung von Sekundärdaten wurden die für die Untersuchung benötigten Informationen unter Nutzung der in Kapitel 3.2 dargestellten qualitativen und quantitativen Methoden zur Befragung von geeigneten Praxisvertretern in Form von aktuellen bzw. potenziellen Anwendern und Anbietern erhoben. Die Berücksichtigung dieser **Stakeholder-Perspektive** führte zu dem im weiteren Verlauf verwendeten Anforderungsbegriff⁶⁴¹. Zur systematischen Erfassung relevanter Anforderungen (AF) wurde ein mehrstufiges Vorgehen umgesetzt (siehe Abbildung 58), dessen wesentliche Schritte sich am **Requirements Engineering** (RE) orientierten. Anstelle der Betrachtung spezifischer Softwaresysteme für den Einsatz in bestimmten Anwendungsfällen, wie es typischerweise Gegenstand des RE ist⁶⁴², fand für das vorliegende Forschungsziel eine Erhebung übergreifender Anforderungen in Bezug auf das Untersuchungsfeld statt.⁶⁴³

⁶⁴¹ Vgl. Balzert (2009), S. 455

⁶⁴² Vgl. Partsch (2010), S. 20; Balzert (2009), S. 434

⁶⁴³ Vor diesem Hintergrund wird auch keine Spezifikation von Leistungsanforderungen oder eine Aufwandschätzung vorgenommen. Auch bleiben primär anwendungsfallsspezifische Anforderungen, wie die Realisierung einer Benutzerschnittstelle, unberücksichtigt.

Abbildung 58: Vorgehen bei der Anforderungserhebung⁶⁴⁴

Analog zum RE sah der erste Schritt des gewählten Vorgehens eine Ermittlung der Anforderungen unter Einbeziehung der Stakeholder vor⁶⁴⁵. Um möglichst vielfältige Perspektiven mit entsprechenden Hintergrundinformationen erfassen zu können, wurde hierfür eine **Gruppendiskussion** durchgeführt. Anschließend bedurfte es einer „präzisen Anforderungsspezifikation“⁶⁴⁶, wofür die ermittelten Anforderungen unter Berücksichtigung von Zusammenhängen in unterschiedliche Ebenen systematisiert sowie in eine einheitliche, prägnante Formulierung überführt wurden. Um bei einer Vielzahl von Anforderungen etwaige Bedeutungsunterschiede identifizieren zu können, ist eine Priorisierung von Anforderungen vorzunehmen.⁶⁴⁷ Hierfür wurde eine **Onlinebefragung** genutzt, welche neben der Erhöhung der Stichprobe auch eine Quantifizierung der Ergebnisse ermöglichte. Die identifizierten Anforderungen wurden dabei hinsichtlich ihrer Bedeutung für einen erfolgreichen Einsatz von ML-Anwendungen im Logistikmanagement und ihres gegenwärtigen Umsetzungsstands in den Unternehmen bewertet. Die aufbereiteten Befragungsergebnisse wurden im nächsten Schritt von mehreren Praxisvertretern im Rahmen von **Experteninterviews** interpretiert, was auch eine Reflexion der jeweiligen Ausprägungen in den Unternehmen umfasste. Im Rahmen dieser semistrukturierten Befragungen konnte zudem die Eignung und Vollständigkeit der identifizierten Anforderungen im Sinne einer Validierung überprüft werden, was der notwendigen Qualitätsbewertung der Ergebnisse diente⁶⁴⁸.

Für die Gestaltung eines erfolgreichen Einsatzes von ML-Anwendungen im Logistikmanagement wurden insgesamt **28 relevante Anforderungen** ermittelt, die unter Berücksichtigung bestehender Taxonomien aus der Literatur⁶⁴⁹ anhand von drei übergeordneten Gruppen in Hinblick auf die Modellierung des Untersuchungsfeldes aus Kapitel 2.5 systematisiert wurden (siehe Abbildung 59). Zum einen sah dies eine Separierung von Anforderungen vor, welche sich explizit auf die Gestaltung der Adoptionsobjekte in Form der ML-Anwendungen beziehen und im weiteren Verlauf als **Systemeigenschaften** bezeichnet werden. Diese wurden zusätzlich nach funktionalen und nichtfunktionalen Anforderungen unterteilt, wobei für letztere auch der Begriff der **Qualitätseigenschaften** verwendet wird. Über primär technische Merkmale hinaus, wie sie bspw. Bestandteil der für Softwaresysteme zutreffenden Norm *ISO/IEC 25010:2011* sind, wurden auch Eigenschaften in Bezug auf die Wirtschaftlichkeit,

⁶⁴⁴ Eigene Darstellung

⁶⁴⁵ Vgl. Balzert (2009), S. 507

⁶⁴⁶ Partsch (2010), S. 44

⁶⁴⁷ Vgl. Balzert (2009), S. 543

⁶⁴⁸ Vgl. Partsch (2010), S. 51 ff.

⁶⁴⁹ Dies umfasst die Veröffentlichungen von Partsch (2010), S. 27 ff.; Balzert (2009), S. 465.

strategische Passung und rechtliche Konformität unter dieser Gruppe subsumiert. Zum anderen wurden diejenigen Anforderungen separiert, die sich entsprechend der systemtheoretischen Modellierung des Untersuchungsfeldes in Kapitel 2.5 auf die Gestaltung des Umfeldes von ML-Anwendungen beziehen. Neben primär technischen Merkmalen der unmittelbaren Systemumgebung umfassen diese **Umfeldeigenschaften** auch weitere Voraussetzungen inner- und außerhalb der adoptierenden Unternehmen, wie z. B. auf- und ablauforganisatorische sowie rechtliche, ethische und strategische Merkmale.

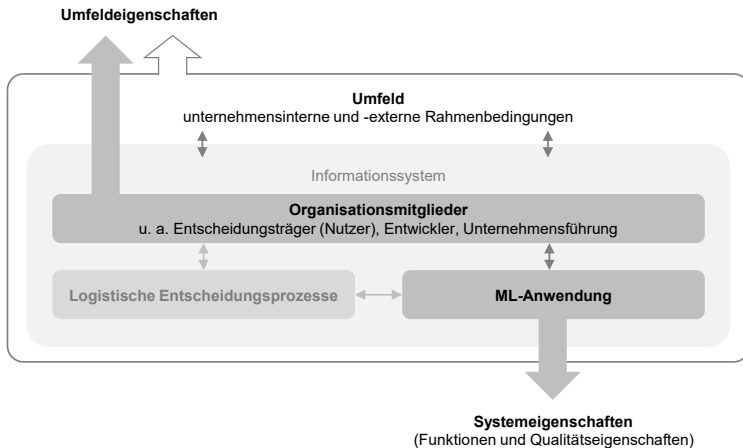


Abbildung 59: Anforderungsgruppen⁶⁵⁰

Entsprechend ihrer jeweiligen Gruppenzugehörigkeit werden die ermittelten Anforderungen in den nachfolgenden drei Unterkapiteln präzisiert und anschließend detailliert beschrieben. Diese **Anforderungsbeschreibung** folgt größtenteils einer einheitlichen Struktur mit folgenden Informationen:

- Erklärungen mit Bezug zu betroffenen Gestaltungsbereichen von Unternehmen,
- Bedeutung mit Bezug zu ML-spezifischen Eigenschaften und angestrebten Wirkungen,
- Umsetzungsstand in der Praxis mit resultierenden Herausforderungen.

Zwischen den ermittelten Anforderungen bestehen sowohl innerhalb als auch übergreifend der Gruppen inhaltliche Wechselwirkungen, auf die im Text entsprechend verwiesen wird.

6.2 Funktionen

Im Rahmen der empirischen Untersuchung wurden **vier übergreifende Funktionen** von ML-Anwendungen ermittelt, die für einen erfolgreichen Einsatz von ML-Anwendungen im Logistik-

⁶⁵⁰ Eigene Darstellung

management vorliegen müssen. In Bezug auf die beiden Funktionen der Lern- und Entscheidungsfähigkeit erfolgte zudem eine Unterscheidung in mehrere Szenarien zur Realisierung einer systemseitigen Autonomie. Die einzelnen Funktionen werden im vorliegenden Subkapitel charakterisiert und sind vorab in Form einer präzisen Anforderungsformulierung in Tabelle 16 zusammengefasst.

Eigenschaft	Kurzbeschreibung
Lernfähigkeit	Die ML-Anwendungen müssen sich an neue Bedingungen anpassen können und diese bei ihren zukünftigen Ergebnissen berücksichtigen.
Entscheidungsfähigkeit	Die ML-Anwendungen sollen stets geeignete Aktionen für die Ausführung von Geschäftsprozessen generieren.
Auswirkungsermittlung	Die ML-Anwendungen sollen die Auswirkungen ihrer generierten Aktionen aufzeigen.
Szenarienbildung	Die ML-Anwendungen sollen verschiedene Ergebnisse aufzeigen, aus denen die Nutzer die geeignetste Option auswählen können.

Tabelle 16: Funktionen – Anforderungspräzisierung

6.2.1 Lernfähigkeit

ML-Anwendungen müssen in der Lage sein, auch bei veränderten Problemstellungen geeignete Ergebnisse zu generieren. Dies erfordert eine eigenständige Anpassung des systemseitigen Wissens, was unter der Funktion der **Lernfähigkeit** zusammengefasst wird und ein Abgrenzungsmerkmal zu anderen Systemen darstellt, bei denen hierfür eine manuelle Programmierung notwendig ist (siehe Kapitel 2.4.2.4). Im Falle von ML-Anwendungen erfolgt die Aktualisierung der Problemlösungsfähigkeit durch den Zugang neuer Daten aus der Umwelt, die zu einer Rekonfiguration der ML-Modelle im Rahmen eines Re-Trainings führen, z. B. in Form einer Veränderung der Merkmalsgewichtungen oder der Neujustierung von Modellparametern. In Abhängigkeit der Lernverfahren kann es sich dabei um Daten zu bestehenden Merkmalen und/oder zu den Zielvariablen handeln, die den Systemen bisher unbekannt sind, was neben der Bereitstellung aktueller Fälle in Form von Echtzeitdaten auch eine Erweiterung des historischen Betrachtungszeitraums der bisherigen Daten umfasst. Die neuen Daten können den bestehenden Datensatz stetig ergänzen oder Teile davon ersetzen. Um insbesondere bei dynamischen Umweltsituationen das Risiko von falschen Entscheidungen zu minimieren, ist – ausgehend von einem initialen Training in der Modellentwicklung – eine **regelmäßige Aktualisierung der Modelle** bzw. Anwendungen während des Betriebs zu realisieren.

6.2.2 Entscheidungsfähigkeit

Auf Grundlage ihrer systemseitigen Ergebnisse müssen ML-Anwendungen geeignete Aktionen für die Ausführung der jeweiligen Geschäftsprozesse generieren. Diese Funktion der **Entscheidungsfähigkeit** entspricht der vorletzten Phase von Entscheidungsprozessen in Form der Auswahl einer geeigneten Handlungsalternative zur Lösung von Problemen (siehe Kapitel

2.3.2). Die geforderte Funktion ist bei bestimmten technischen Gestaltungsformen von ML-Anwendungen immanent, insbesondere im Falle von Optimierungsanwendungen, da diese explizit einer systemseitigen Unterstützung der genannten Phase dienen (siehe Kapitel 5.2.1.4). Jedoch existiert auch eine Vielzahl von Anwendungen, welche mit dem Ziel einer Unterstützung von vorgelagerten Aktivitäten in Entscheidungsprozessen, wie der Problemwahrnehmung oder allgemein der Informationsbeschaffung, umgesetzt werden. In diesen Fällen, wozu insbesondere Identifikations- und Prognoseanwendungen zu zählen sind, werden zusätzliche technische Komponenten zur Entscheidungsfähigkeit benötigt. Für deren Realisierung kann erneut auf ML zurückgegriffen werden, wie z. B. beim Anwendungsfall 3 aus Kapitel 4.3.3, bei dem zusätzlich zu einer ML-basierten Prognose der Absatzmenge von Produkten auch darauf basierende Aktionen für die Bestandsplanung in Form geeigneter Bestellmengen und -zeitpunkte für die benötigten Materialien ermittelt werden. Zumeist findet bei den aktuellen Anwendungen die systemseitige Generierung von Aktionen jedoch durch andere IT-Systeme statt, welche die Ergebnisse der ML-Anwendungen als Input erhalten.

6.2.3 Autonomie

Im Zusammenhang mit der Lern- und Entscheidungsfähigkeit wurden auch Forderungen zur eigenständigen Ausführung der damit verbundenen Aktivitäten durch die ML-Anwendungen gestellt, d. h. hinsichtlich der Veränderung des Wissens und der Realisierung der generierten Aktionen bzw. Ergebnisse. Für die damit verbundene Autonomie kommen grundsätzlich mehrere Ausprägungen infrage, die sich anhand der Verteilung der Aufgaben zwischen den Systemen und Menschen unterscheiden lassen.⁶⁵¹ Die jeweilige Zusammenarbeitsform von beiden „Akteuren“ ist im Rahmen von arbeitsorganisatorischen Betrachtungen zu gestalten und kann – ausgehend von dem übergeordneten Begriff der Mensch-Maschine-Interaktion – im Falle von Softwaresystemen als **Mensch-Computer-Interaktion** (HCI) bezeichnet werden.⁶⁵² Für die Abstufung der Aufgabenteilung wird in der Regel eine Systematisierung in mehrere **Autonomiestufen** vorgenommen, wofür in der Literatur verschiedene Ansätze zur Verfügung stehen.⁶⁵³ Eine anerkannte Taxonomie findet sich in der Norm *ISO/SAE PAS 22736:2021*, welche für den Anwendungsfall des autonomen Fahrens ausgehend von einem rein manuellen Szenario fünf Autonomiestufen vorsieht. Unter Berücksichtigung dieser Ansätze wurde für die vorliegende Untersuchung eine geeignete Systematik abgeleitet, welche – abweichend zu der bisher vorherrschenden isolierten Betrachtung der Entscheidungsfähigkeit, bei der die Lernfähigkeit lediglich impliziert betrachtet wird – eine **Differenzierung in beide Funktionen** umfasst (siehe Abbildung 60). Die resultierenden Autonomiestufen werden im Folgenden zusammen mit den Präferenzen der befragten Unternehmen für die Gestaltung von ML-Anwendungen zum Einsatz im Logistikmanagement beschrieben.

⁶⁵¹ Vgl. Gottschalk-Mazouz (2019), S. 238

⁶⁵² Vgl. Karafillidis (2019), S. 157

⁶⁵³ Vgl. Beer et al. (2014), S. 77 f.




Abbildung 60: Autonomiestufen von ML-Anwendungen⁶⁵⁴

Für die Autonomie der Lernfähigkeit ist in der gewählten Systematik eine Unterteilung in **drei Stufen** vorgesehen. In der ersten Stufe erfolgt eine aktive Beeinflussung des Lernprozesses durch den Menschen, indem dieser ein erneutes Training manuell initiiert und ggf. selbst entwicklungsseitige Veränderungen vornimmt. Die zweite Stufe sieht eine automatische Durchführung dieses Re-Trainings vor, wobei jedoch die modellseitigen Veränderungen und damit das neue Wissen der Anwendungen durch den Menschen freigegeben werden müssen. In der dritten Stufe entfällt diese Freigabe, sodass das automatisch generierte Wissen direkt im Betrieb verwendet wird, wobei auch bestimmte Grenzen festgelegt werden können. Die automatische Initiierung des Lernprozesses in der zweiten und dritten Stufe kann durch unterschiedliche Impulse erfolgen. Dies umfasst zum einen die Festlegung eines Zeitplans, der z. B. ein allnächtliches Re-Training vorsieht. Zum anderen ist auch ein ereignisbasiertes Lernen realisierbar, bei dem z. B. im Falle einer festgelegten Anzahl neuer Daten oder im Falle des Überschreitens eines definierten Schwellwertes in Bezug auf die Ergebnisqualität das Re-Training ausgelöst wird. Die Zeitintervalle oder Ereignisse können dabei sehr kurz bzw. niedrighschwellig definiert werden, sodass bspw. bei jedem neuen Fall ein Re-Training erfolgt, was einer nahezu permanenten Aktualisierung der Systeme entspricht (sog. Online Learning).

⁶⁵⁴ Eigene Darstellung

Die erste Autonomiestufe der Lernfähigkeit wird von keinem der Unternehmen für den Einsatz im Logistikmanagement präferiert (siehe Abbildung 61). Stattdessen sollen die ML-Anwendungen eigenständig neues Wissen generieren und produktiv einsetzen können. Hinsichtlich der Notwendigkeit einer damit verbundenen Freigabe durch den Menschen besteht nahezu eine Indifferenz. In diesem Zusammenhang wurde auch auf die Abhängigkeit der beiden Gestaltungsoptionen von den jeweiligen systemseitigen Qualitätseigenschaften hingewiesen, insbesondere in Bezug auf die Zuverlässigkeit und Manipulationssicherheit. Bei der Betrachtung der bestehenden ML-Anwendungen im Logistikmanagement zeigt sich, dass diese zumeist nur in einer geringen Frequenz aktualisiert werden. Das Re-Training erfolgt dabei entweder nach fest definierten Abständen oder auch **vielfach noch durch manuelle Intervention**. Neben einem eingeschränkten Vertrauen in die Ergebnisqualität wird dies v. a. mit der entwicklungsseitigen Komplexität bei der Realisierung eines kontinuierlichen Datenaustausches mit den Input-Systemen und bei der Automatisierung von Modellanpassungen begründet.




Abbildung 61: Lernfähigkeit – Bewertung der Autonomiestufen⁶⁵⁵

Für die Entscheidungsfähigkeit sind in der Systematik **vier Autonomiestufen** vorgesehen. In der ersten Stufe fungieren die Systeme lediglich als Entscheidungsunterstützung, indem eine Bereitstellung der systemseitigen Ergebnisse für die Nutzer im Sinne eines Vorschlages erfolgt. Die Ausführung von Entscheidungen in Form von Aktionen zur Veränderung von Geschäftsprozessen verbleibt vollständig beim Menschen. In der zweiten Stufe führen die Systeme bereits bestimmte Prozessumfänge eigenständig aus, indem die systemseitig generierten Aktionen zu einer direkten Veränderung der Geschäftsprozesse führen. Der Mensch kontrolliert allerdings die Entscheidungen der Systeme vor deren Realisierung. Zusätzlich übernimmt er die Ausführung der restlichen Prozessumfänge. In der dritten Stufe werden auch diese Prozesse an die Systeme übergeben, sodass einzig die Kontrolle beim Menschen verbleibt. Eine zusätzliche Übergabe dieser Aufgabe an die Systeme sieht die letzte Stufe der vollständigen autonomen Ausführung vor.

Nahezu alle Unternehmen sehen eine Übertragung der Entscheidungsausführung auf ML-Anwendungen vor (siehe Abbildung 62). Lediglich 5 % präferieren deren assistierenden Einsatz. Auf der anderen Seite ist aber auch nur bei einem kleinen Teil der Unternehmen (7 %) eine Präferenz für eine vollautonome Ausführung festzustellen. Deutlich mehr Unternehmen (36 %)

⁶⁵⁵ Eigene Darstellung

bevorzugen im Rahmen der vollständigen systemseitigen Ausführung – analog zur Lernfähigkeit – weiterhin eine Kontrolle durch den Menschen. Die Mehrheit (60 %) sieht eine Aufgabenteilung zwischen Menschen und Systemen vor. Hierzu wird eine **Unterscheidung in Standard- und Sonderprozesse** als zweckmäßig angesehen, wobei letztere weiterhin manuell ausgeführt werden sollen. Die Notwendigkeit einer Aufteilung zwischen beiden Akteuren und einer fortbestehenden Kontrolle durch den Menschen wird von den befragten Unternehmen ebenfalls mit den Eigenschaften der aktuellen ML-Anwendungen begründet, welche oft noch nicht die benötigte Zuverlässigkeit für einen autonomen Betrieb aufweisen. Gleichzeitig wird auch auf Hemmnisse in den Unternehmen zur Verlagerung der Entscheidungsausführung auf IT-Systeme verwiesen, welche insbesondere bei geschäftskritischen Prozessen zu beobachten sind. Dies führt dazu, dass die meisten der bestehenden Systemen im Logistikmanagement bislang als **reine Entscheidungsunterstützung** eingesetzt werden.




Abbildung 62: Entscheidungsfähigkeit – Bewertung der Autonomiestufen⁶⁵⁶

Anhand der Autonomiestufen zu beiden Funktionen ergeben sich grundsätzlich verschiedene Kombinationsmöglichkeiten für die Gestaltung der Zusammenarbeit zwischen ML-Anwendungen und Menschen. Hieraus lassen sich drei bedeutende Szenarien aggregieren. Ausgehend von einer weiterhin aktiven Einbindung des Menschen in jede einzelne Entscheidung in Form einer Freigabe der jeweiligen Aktionen und/oder der vorgenommenen Modellanpassungen, kann sich der Einsatz des Menschen auch auf Kontrollaufgaben beschränken, welche ihm jedoch jederzeit die Möglichkeit geben, in den Lernprozess und/oder die Entscheidungsausführung einzugreifen. Diese beiden Szenarien werden als **Human-in-the-Loop (HITL)** und **Human-on-the-Loop (HOTL)** bezeichnet.⁶⁵⁷ Zusätzlich existiert auch die Möglichkeit eines vollautonomen Einsatzes, wofür bei beiden Funktionen eine Realisierung der höchsten Autonomiestufe erforderlich ist. Demnach müssen die Systeme in diesem Szenario sowohl eigenständig Wissen auf Basis neuer Daten generieren als auch darauf basierende Aktionen eigenständig ausführen. Die Veränderungen, die sich auf Basis der ausgeführten Aktionen in der Umwelt ergeben, werden hierbei ebenfalls durch die Systeme wahrgenommen und führen im Sinne eines Feedbacks zur automatischen Anpassung ihres Verhaltens. Diese **definitionsge-
mäßige Autonomie von Systemen**⁶⁵⁸ entspricht einem Schließen des Perception-Action-Cycle.

⁶⁵⁶ Eigene Darstellung

⁶⁵⁷ Vgl. Europäische Kommission (2019), S. 16

⁶⁵⁸ Vgl. Gottschalk-Mazouz (2019), S. 239

6.2.4 Auswirkungsermittlung und Szenarienbildung

Für das von den Logistikvertretern präferierte Szenario einer bestehenden aktiven Einbindung des Menschen bei der Entscheidungsausführung im Sinne des HITL werden zwei weitere Funktionen von ML-Anwendungen gefordert, die einer Unterstützung der Nutzer dienen.

Zum einen sollen die Systeme für die generierten Aktionen zusätzliche Informationen in Form der potenziellen **Auswirkungen** im jeweiligen Anwendungsfall ermitteln, wozu z. B. Veränderungen von Geschäftsprozessen und Leistungsindikatoren zählen. Die Anforderungsermittlung kann mittels Heuristiken oder Simulationen realisiert werden; zudem ist auch ein Rückgriff auf die Prognosefähigkeit von ML möglich. Bei den bisherigen ML-Anwendungen im Logistikmanagement ist diese Funktionen bisher nur vereinzelt vorzufinden, was auch im Zusammenhang mit deren häufig fehlender Entscheidungsfähigkeit steht. Anstelle von Auswirkungen werden aber teilweise systemseitige Zusatzinformation in Form der Ergebnisqualität bereitgestellt.

Zum anderen müssen ML-Anwendungen – anstelle eines einzelnen Ergebnisses – mehrere Optionen aufzeigen, anhand derer die Entscheidungsträger eine Auswahl treffen können. Bei diesen **Szenarien** kann es sich um mehrere Ergebnisse einer Modellkonfiguration handeln, die z. B. entsprechend der erzielten Güte im Sinne eines Rankings ausgegeben werden. Ferner besteht auch die Möglichkeit einer Nutzung von mehreren Modellen mit unterschiedlichen Konfigurationen, z. B. in Form abweichender Lernverfahren, deren jeweilige Ergebnisse bereitgestellt werden. Die Funktion der Szenarienbildung wird bereits durch einige der bestehenden Anwendungen abgedeckt, indem z. B. mehrere Ergebnisse eines Modells mit entsprechenden Wahrscheinlichkeitsverteilungen ausgegeben werden.

6.3 Qualitätseigenschaften

Zusätzlich zu den genannten Funktionen wurden für die Qualität von ML-Anwendungen **zehn Eigenschaften** ermittelt, die für einen erfolgreichen Einsatz von ML-Anwendungen im Logistikmanagement vorliegen müssen. Diese Qualitätseigenschaften werden im vorliegenden Subkapitel charakterisiert und sind vorab in Form einer präzisen Anforderungsformulierung in Tabelle 17 zusammengefasst.

Eigenschaft	Kurzbeschreibung
Zuverlässigkeit	Die ML-Anwendungen müssen zuverlässige Ergebnisse bereitstellen – auch bei komplexen Problemen und fehlerhaften bzw. wenigen Daten.
Nachvollziehbarkeit	Der Lösungsweg der ML-Anwendungen muss für die Nutzer nachvollziehbar sein.
Kontrollierbarkeit der Entscheidungsausführung	„Falsche“ Ergebnisse der ML-Anwendungen oder deren Fehlbenutzung müssen erkannt bzw. verhindert werden, bevor darauf basierende Aktionen ausgeführt werden.
Kontrollierbarkeit und Rückverfolgbarkeit des Lernprozesses	Der Lösungsweg und die Ergebnisse der ML-Anwendungen müssen (durch den Menschen) überprüfbar, beeinflussbar und rekonstruierbar sein.

Manipulationssicherheit	Der Lösungsweg der ML-Anwendungen muss gegenüber dem Eingriff unbefugter Dritter abgesichert sein.
Verfügbarkeit	Die ML-Anwendungen müssen hochverfügbar sein, auch wenn Teile ihrer Infrastruktur ausfallen.
Business Case	Aus der Nutzung der ML-Anwendungen müssen Einsparpotenziale hervorgehen, die vorab klar aufgezeigt werden können.
Skalierbarkeit	Die ML-Anwendungen müssen um mehrere Anwendungsfälle erweiterbar sein und sollen keine Inselösung darstellen.
Strategic Fit	Die ML-Anwendungen müssen einen klaren Bezug zur Strategie, zur Vision und/oder zu zukünftigen Anforderungen der Unternehmen aufweisen.
Compliance	Die ML-Anwendungen müssen unternehmensinterne und -externe Regeln einhalten, insbesondere bezüglich der Datensicherheit, des Datenschutzes und ethischer Standards.

Tabelle 17: Qualitätseigenschaften – Anforderungspräzisierung

6.3.1 Zuverlässigkeit

Für den Einsatz im Logistikmanagement müssen die ML-Anwendungen während des gesamten Betriebs zuverlässige Ergebnisse in Form funktional korrekter Entscheidungen bereitstellen. Dies gilt auch im Falle von komplexen Problemstellungen. Demnach wird neben einem Umgang mit mehreren konfliktären Zielstellungen auch eine **hohe Ergebnisqualität** der Systeme bei sich ändernden Umfeldbedingungen erwartet. Diese Notwendigkeit verstärkt sich im Falle der angestrebten Umsetzung autonomer Entscheidungen. Entsprechend der gegenwärtigen datenseitigen Voraussetzungen in der Logistik (siehe AF Datenverfügbarkeit und AF Datenqualität) werden zudem Systeme gefordert, welche auch bei wenigen sowie bei fehlerhaften bzw. verrauschten Daten eine hohe Zuverlässigkeit sicherstellen.

Zur Realisierung dieser Forderung sind ML-Modelle mit einer hohen Genauigkeit zu entwickeln, wobei sich dies nicht nur auf die Trainingsfälle, sondern auch auf unbekannte Fälle mit abweichenden Verteilungen bezieht, weshalb eine Generalisierbarkeit der Modelle sicherzustellen ist. Auch wenn vorab auf analytischem Wege für bestimmte entwicklungsseitige Gestaltungsparameter eine indikative Eingrenzung möglich ist, kann die für den jeweiligen Anwendungsfall geeignetste Lösung aufgrund der individuellen prozess- und datenseitigen Voraussetzungen nur durch eine direkte Implementierung und Testung verschiedener Ansätze im Sinne eines **Trial-and-Error-Vorgehens** identifiziert werden. Aus diesem Grund sollen die mit der Entwicklung betrauten Mitarbeiter durch geeignete Maßnahmen zur einer experimentellen Erprobung verschiedener Lösungsansätze, u. a. in Bezug auf unterschiedliche Modellkonfigurationen, Lernverfahren und Merkmale, motiviert werden.

Die Bewertung der einzelnen Lösungsansätze soll nach objektiven Kriterien erfolgen, wofür mehrere statistische Metriken, wie der RMSE und MAE, zur Verfügung stehen (siehe Kapitel 2.4.3.2). Neben dieser technischen Bewertung wird hierzu aber auch die konsequente Berücksichtigung einer **betrieblichen Perspektive** gefordert. Dies betrifft die Verwendung geeigneter prozessspezifischer Güteindizes, welche die spezifischen betrieblichen Anforderungen an die

Ergebnisqualität besser abbilden sollen und gemeinsam mit den jeweiligen Prozessverantwortlichen bzw. -eigentümern (Process Owner) festzulegen sind. Hierbei sollen auch etwaige Unterschiede von einzelnen Anwendungsfällen und Stakeholdern betrachtet werden, indem z. B. höhere Anforderungen an kurzfristige als an langfristige Prognosen bestehen.

Die gegenwärtigen ML-Anwendungen im Logistikmanagement liefern bereits für viele Anwendungsfälle vielversprechende Ergebnisse, welche sich im Vergleich zum Menschen, aber auch zu anderen technischen Ansätzen durch eine höhere Genauigkeit bei einer gleichzeitig kürzeren Bearbeitungszeit auszeichnen. Hierbei zeigt sich auch die Lösungsmöglichkeit von sehr komplexen Problemstellungen, wie der Optimierung der Maschinenbelegung oder der Prognose von Prozesszeiten bei sehr dynamischen Einflussvariablen. Es ist aber auch festzustellen, dass **viele Entscheidungsprozesse bisher noch nicht abgedeckt** sind. Auch beschränken sich die bestehenden Systeme entsprechend ihres Prototypenstadiums oft nur auf ausgewählte Anwendungsbereiche, sodass in diesen Fällen noch keine Aussagen über die Ergebnisqualität bei sich verändernden Problemstellungen getroffen werden können. Zudem wird ein Handlungsbedarf bei der Realisierung zufriedenstellender Lösungen für **Problemstellungen mit wenig Daten** gesehen.

6.3.2 Nachvollziehbarkeit

Die im Logistikmanagement eingesetzten ML-Anwendungen müssen Möglichkeiten zur Nachvollziehbarkeit ihres Lösungsweges für den Menschen bieten, damit diese kontextbezogen das **Zustandekommen der Entscheidungen** verstehen können. Zur Realisierung dieser Forderung muss eine Erklärbarkeit der jeweils wirkenden mathematisch-statistischen Zusammenhänge der zugrundeliegenden Modelle in Verbindung mit den verwendeten Daten sichergestellt werden. Dies wird jedoch durch den **Black-Box-Charakter** vieler Modelle erschwert (siehe Kapitel 2.4.3.2), sodass die bisherigen Anwendungen im Logistikmanagement oft von einer hohen Intransparenz geprägt sind. Neben verbesserten Möglichkeiten zur Kontrollierbarkeit der Anwendungen soll diese Eigenschaft v. a. einer Akzeptanzsteigerung bei den Mitarbeitern dienen. Auch soll damit eine Einsatzmöglichkeit für Anwendungsfälle, welche aus ethischen und rechtlichen Gründen eine Transparenz über die jeweilige Entscheidungsfindung erfordern, sichergestellt werden. Es wird von den befragten Unternehmen aber auch eine Differenzierung nach unterschiedlichen Stakeholdern und Anwendungsfällen vorgenommen. Demnach müssen die Entwickler der Anwendungen über ein deutlich höheres Verständnis zum jeweiligen Lösungsweg verfügen. Dagegen wird für die Nutzer eine **Kenntnis von grundlegenden Systemeigenschaften** als ausreichend erachtet, welche sich u. a. auf die jeweils einbezogenen Merkmale und das allgemeine Systemverhalten bezieht (siehe AF Kompetenz). Auch wird im Falle eines lediglich unterstützenden Einsatzes der Systeme für die meisten Anwendungsfälle im Logistikmanagement eine höhere Intransparenz akzeptiert.

6.3.3 Kontrollierbarkeit der Entscheidungsausführung

Im Falle von relevanten Einschränkungen in Bezug auf die Zuverlässigkeit von ML-Anwendungen müssen die entsprechenden ungeeigneten bzw. fehlerhaften Entscheidungen vor einer manuellen oder automatischen Ausführung, z. B. in Form einer Weitergabe dieser Informationen an andere Systeme, erkannt werden. Dies dient im Wesentlichen der Vermeidung von schädlichen Auswirkungen für das Unternehmen, aber gleichzeitig auch dem Abbau von Ängsten bei den Beteiligten. Hierzu werden technische Möglichkeiten zur Realisierung einer **Ex-ante-Kontrolle für alle Einzelentscheidungen** gefordert. Dies gilt auch in Fällen einer hohen Ergebnisqualität vorausgehender Entscheidungen, da sich das Verhalten von ML-Anwendungen bzw. der zugrundeliegenden Modelle durch verschiedene Umstände verschlechtern kann, von denen einige nachfolgend aufgeführt sind:

- Die Modelle weisen entwicklungsseitige Defizite auf, indem z. B. wichtige reale Phänomene nicht korrekt berücksichtigt wurden.
- Die zum Training der Modelle berücksichtigten Daten waren ungeeignet, da sie nur einen Ausschnitt der realen Phänomene abdecken.
- Die bisher genutzten Daten waren geeignet, jedoch haben sich seitdem die realen Bedingungen verändert.
- Die systemseitige Erfassung der benötigten Daten hat sich verändert, wodurch z. B. die Merkmale und Erhebungszeitpunkte nicht mehr korrekt abgebildet werden.

Zur manuellen Kontrolle der Systeme wird die Realisierung einer Benutzerschnittstelle (UI) gefordert. Darüber hinaus bedarf es einer **systemseitigen Selbstüberwachung**, die aus der eingeschränkten Nachvollziehbarkeit von ML-Anwendungen resultiert und eine Unterstützungsfunktion für den Menschen darstellen soll. Für das vollautonome Szenario stellt diese Eigenschaft zudem eine zentrale Voraussetzung dar. Über die systemseitigen Fehler hinaus soll für bestimmte Anwendungsfälle auch eine **Detektion menschlicher Fehlentscheidungen** durch die Systeme ermöglicht werden. Dazu müssen die Nutzer ihre Entscheidungen vor deren Ausführung an die Systeme übergeben, was bei der Gestaltung der jeweiligen UI zu berücksichtigen ist. Einige der bisherigen ML-Anwendungen im Logistikmanagement weisen bereits Kontrollmechanismen auf, indem bspw. die Ergebnisse in Hinblick auf definierte Toleranzgrenzen geprüft werden und eine Meldung von abweichenden Entscheidungen an die Nutzer erfolgt. Eine Forcierung dieser Eigenschaft bei der Entwicklung erfolgt jedoch bisher nicht, was auch mit dem bisher dominierenden Einsatz der Systeme als Entscheidungsunterstützung begründet wird.

6.3.4 Kontrollier- und Rückverfolgbarkeit des Lernprozesses

Die Möglichkeit zur Kontrolle der ML-Anwendungen muss nicht nur für die systemseitigen Ergebnisse gegeben sein, sondern auch für die damit verbundene systemseitige Entscheidungsfindung in Form des jeweiligen Lösungsweges. Diese Forderung bezieht sich sowohl auf aktuelle als auch auf vergangene Entscheidungen im Sinne einer **Ex-post-Kontrolle**, sodass in

diesem Kontext auch von einem „Tracking und Tracing“ gesprochen wird. Dadurch sollen eine gezielte Beeinflussung und eine nachträgliche Plausibilisierung einzelner Entscheidungen durch die beteiligten Mitarbeiter ermöglicht werden, z. B. im Falle von kundenseitigen Reklamationen.

Für die geforderte Realisierung der Kontrollier- und Rückverfolgbarkeit bedarf es der Generierung von Informationen zur **Qualifizierung des systemseitigen Lernprozesses**. Zudem müssen diese Informationen nutzerorientiert aufbereitet und über eine UI dargestellt werden, was die Forderung der Nachvollziehbarkeit von ML-Anwendungen ergänzt. Auch bedarf es deren Speicherung, wobei der benötigte Zeitraum anwendungsfallspezifisch festzulegen ist, z. B. unter Berücksichtigung von rechtlichen Vorgaben. Die dadurch verfügbaren Informationen zu historischen Einzelentscheidungen sollen ebenfalls zur Bewertung eines aggregierten Systemverhaltens genutzt werden, was der Extraktion von Wissen zu den jeweiligen Anwendungsfällen sowie der Identifikation von Verbesserungsmöglichkeiten dienen kann.

6.3.5 Manipulationssicherheit

Die im Logistikmanagement eingesetzten ML-Anwendungen müssen vor einem unbefugten Eingriff geschützt werden, wobei dies sowohl für externe Cyberangriffe als auch für eine unbewusste Manipulation durch autorisierte Nutzer gefordert wird. Als sicherheitskritische Komponenten werden zum einen die ML-Modelle betrachtet, bei denen u. a. durch eine Manipulation der Algorithmen schädliche Entscheidungen der Systeme herbeigeführt werden können. Zum anderen betrifft dies auch die für das Training genutzten Input-Daten, welche das Risiko zum Auslesen sensibler Informationen sowie zur gezielten Beeinflussung der systemseitigen Ergebnisse bergen. Demnach kann durch eine subtile Manipulation der Daten über einen längeren Zeitraum hinweg der Lernprozess verändert werden. Durch die häufig hohe Anzahl von unterschiedlichen Datenquellen bei ML-Anwendungen liegen viele potenzielle Angriffsmöglichkeiten vor. Vor diesem Hintergrund werden geeignete Maßnahmen gefordert, welche zur **Vermeidung dieser bewussten und unbewussten Manipulationen** entlang der gesamten IT-Infrastruktur von ML-Anwendungen beitragen. Darüber hinaus soll im Falle eines erfolgten Eingriffes eine schnelle Detektion und effektive Mitigation der Auswirkungen erfolgen. Aus Sicht der befragten Unternehmen bedarf es dazu einer Erweiterung der bisherigen Instrumente der IT-Sicherheit. Gleichzeitig wird aber auch auf die fehlenden gesetzlichen Sicherheitsstandards für ML bzw. KI hingewiesen.

Für die bisher lokal betriebenen ML-Anwendungen werden zur Manipulationssicherheit vordergründig Instrumente von konventionellen IT-Systemen genutzt, wozu u. a. Firewalls, Anti-Ransomware, Zwei-Faktor-Authentifizierungen und Penetrationstests gehören. Einem semi- oder vollautonomen Einsatz von ML-Anwendungen werden diese Maßnahmen jedoch nicht gerecht. In diesen Fällen besteht jedoch aufgrund der eingeschränkten menschlichen Kontrolle ein besonders hohes Sicherheitsrisiko, was Dritte zu Angriffen motivieren und im Falle von kritischen Geschäftsprozessen zu hohen Schäden führen kann. Eine andere Situation liegt für

die mittels IaaS über externe Cloud-Infrastruktur betriebenen Anwendungen vor, wozu im Kreise der befragten Unternehmen insbesondere Kooperationen mit den Hyperscalern zählen (siehe Kapitel 4.4.2). In diesen Fällen wird von deutlich höheren Sicherheitsstandards berichtet, was neben der höheren Rechenleistung und Flexibilität (siehe AF IT-Performance) einen wesentlichen Beweggrund für diese infrastrukturelle Realisierungsform darstellt.

6.3.6 Verfügbarkeit

Zur Nutzung der systemseitigen Funktionen muss eine hohe Verfügbarkeit der ML-Anwendungen gegeben sein. Es werden daher geeignete Maßnahmen gefordert, die zu einer **Vermeidung von Gesamt- und Teilsystemausfällen** der ML-Modelle und der weiteren technischen Komponenten der Anwendungen beitragen, einschließlich der zugrundeliegenden IT-Infrastruktur mit den einzelnen Input-Systemen. Im Falle eines Eintritts dieser Ereignisse muss zudem die Eindämmung der damit verbundenen Auswirkungen sichergestellt werden. Neben einer redundanten Infrastruktur wird dazu die Einrichtung von Backup-Systemen und Datenarchivierungen gefordert, welche bei einem Systemausfall den Rückgriff auf ältere Versionen erlauben. Hierbei kann es sich um Speicherstände der Anwendungen handeln, welche im Rahmen des Re-Trainings erstellt werden. Darüber hinaus bedarf es konkreter Handlungsanweisungen für die Mitarbeiter, die in Anwendungsfällen mit einer unregelmäßigen Ergebnisbereitstellung auch einen Rückfall auf eine manuelle Ausführung der Entscheidungsprozesse vorsehen können – was jedoch eine gezielte Aufrechterhaltung von deren Problemlösungsfähigkeiten erfordert. Analog zur Manipulationssicherheit bleiben die bisherigen lokal betriebenen ML-Anwendungen hinter den formulierten Anforderungen zurück. Anders verhält es sich bei den Systemen, die auf externer Cloud-Infrastruktur ausgeführt werden. In diesen Fällen werden Verfügbarkeitsgarantien von nahezu 100 % durch die Anbieter zugesagt.

6.3.7 Business Case

Aus dem Einsatz von ML-Anwendungen muss ein messbarer betriebswirtschaftlicher Nutzen für die Unternehmen hervorgehen. Dieser soll zudem bereits zu einem **frühen Zeitpunkt bekannt** sein, damit die Vorteilhaftigkeit der Anwendungen für die Unternehmen bewertet und fundierte Entscheidungen hinsichtlich deren Umsetzung, einschließlich einer Eigen- oder Fremdentwicklung (Build-or-Buy), getroffen werden können. Mehrere der befragten Unternehmen weisen aber auch auf das Innovationshindernis einer zu starken Fokussierung auf die Wirtschaftlichkeit von neuen Technologien hin. Demnach wird zum einen das Risiko gesehen, dass sehr „fortschrittliche“ Konzepte, deren Wirtschaftlichkeit sich aufgrund eines vergleichsweise hohen Aufwands als nachteilig erweist, keine Berücksichtigung finden. Zum anderen sind die mit der Entwicklung betrauten Mitarbeiter von Beginn an in Bezug auf einen bestimmten Lösungsansatz festgelegt. Darüber hinaus wird auf die Herausforderungen bei der **Quantifizierung des Nutzens** von vielen ML-Anwendungen hingewiesen, da mehrere der direkten Wirkungsdimensionen, wie die Verbesserung der Entscheidungsqualität und die Erhöhung der

Transparenz (siehe Kapitel 5.4.1), nur schwer operationalisierbar sind. Aufgrund der Ungewissheit über die Gestaltung des jeweiligen Lösungsansatzes und die damit verbundenen Aufwände sind die Möglichkeiten zur Bestimmung valider Wirtschaftlichkeitsberechnungen vor der eigentlichen Entwicklung von ML-Anwendungen zudem sehr eingeschränkt.

Vor diesem Hintergrund wird es als notwendig erachtet, dass bereits im Rahmen der Konzeption von ML-Anwendungen betriebswirtschaftliche Ziele definiert werden, welche den intendierten Nutzen der Anwendungen über geeignete messbare Zielgrößen aufzeigen. Die Überprüfung dieser Ziele soll allerdings erst nach der Sicherstellung einer technischen Machbarkeit der Anwendungen erfolgen, sodass während des Entwicklungsprozesses ausreichend gestalterische Freiheiten bestehen, aber gleichzeitig auch von Beginn an der betriebliche Mehrwert der Anwendungen forciert wird. Zum Zeitpunkt der Bestätigung der technischen Machbarkeit soll zudem ein formaler Business Case erstellt werden, der die formulierten Ziele konkretisiert und den geplanten Aufwänden im Sinne einer Nutzen-Kosten-Betrachtung verbindlich gegenüberstellt. Die Überprüfung der Zielerreichung soll regelmäßig im Rahmen des produktiven Betriebs vorgenommen werden und mit einem „harten“ Kriterium in Form einer Weiterführung oder einem Abbruch bzw. einer Anpassung des jeweiligen ML-Projektes verbunden sein.

Bei den bisherigen ML-Anwendungen im Logistikmanagement lässt sich eine einseitige Beschränkung auf technische Zielgrößen feststellen, insbesondere auf die Ergebnisqualität. Dagegen werden betriebswirtschaftliche Zielsetzungen oft nicht oder sehr spät festgelegt. Dies wird mit der aktuell vorherrschenden experimentellen Erprobung von ML begründet, welche häufig mit der Fokussierung auf die technische Machbarkeit einhergeht (siehe AF Standardprozesse).

6.3.8 Skalierbarkeit

Im Zusammenhang mit der Wirtschaftlichkeit wird auch die Realisierung von Skaleneffekten bei der Umsetzung von ML-Anwendungen gefordert, welche sich durch deren **Einsatzmöglichkeit für ein breites Anwendungsspektrum** in Form verschiedener Prozesse, Produkte, Standorte o. ä. äußern soll. Ausgehend von einer Entwicklung für einzelne Anwendungsfälle, welche u. a. zur Komplexitätsreduzierung ausgewählt werden (siehe AF Komplexitätsbeherrschung), bedarf es anschließend einer gezielten Erweiterung des Anwendungsbereiches der jeweiligen Systeme. Diese zusätzlichen Anwendungsfälle gehen jedoch in der Regel mit anderen betrieblichen und teilweise nutzerseitigen Anforderungen einher, einschließlich der Erweiterung von Funktionen, was die Überprüfung und Umsetzung veränderter Lösungsansätze erfordert, u. a. in Form der zu berücksichtigenden Daten, Merkmale und Modellkonfigurationen. Neben diesen entwicklungsseitigen Implikationen müssen bei der „prozessualen“ und „funktionalen“ Skalierung auch veränderte Anforderungen an die zugrundeliegende Infrastruktur, u. a. in Form höherer Rechenleistungen und Speicherkapazitäten, berücksichtigt werden, die sich aus einer steigenden Anzahl von Nutzern bzw. Zugriffen sowie einer Anbindung an weitere Input- und Output-Systeme ergeben.

Zur **Vermeidung von hohen technischen Schulden** bei der Anpassung der Anwendungen zur Übertragung auf weitere Anwendungsfälle wird eine frühe Berücksichtigung der damit verbundenen Anforderungen gefordert. Auf der anderen Seite wird aber auch auf den Aufwand und die resultierende Entwicklungskomplexität einer frühen Skalierung der ML-Anwendungen hingewiesen, was häufig den verfügbaren Ressourcen und der geplanten Entwicklungszeit entgegensteht. Vor diesem Hintergrund wird es als zweckmäßig erachtet, dass das erweiterte Anwendungsspektrum und dessen Anforderungen bereits im Rahmen der Konzeption der Anwendungen berücksichtigt werden, was auch eine Ermittlung von Zusammenhängen zwischen den verschiedenen Anwendungsfällen umfasst. Deren entwicklungsseitige Umsetzung kann jedoch zu einem späteren Zeitpunkt erfolgen, wobei dieser unter Berücksichtigung aller projektspezifischen Zielsetzungen und Restriktionen individuell festzulegen ist.

Bei den bisherigen ML-Anwendungen im Logistikmanagement ist eine sehr eingeschränkte Skalierbarkeit festzustellen. Vielmehr handelt es sich in den meisten Fällen um „Insellösungen“, was entweder auf die gezielte Lösung bereichsspezifischer Probleme oder die schnelle Sichtbarmachung von Erfolgen, z. B. in Form von Leuchtturminitiativen (siehe AF Standardprozesse), zurückgeht. Dies schränkt den betriebswirtschaftlichen Nutzen der Anwendungen stark ein und äußert sich in dem in Kapitel 1.1 dargestellten AI Chasm.

6.3.9 Strategic Fit

Über die vorab geforderte Wirtschaftlichkeit hinaus müssen die ML-Anwendungen auch eine **strategische Relevanz** aufweisen, indem sie einen Bezug zu bestehenden langfristigen Vorgaben der jeweiligen Unternehmen aufweisen, z. B. in Form konkreter Zielgrößen, Maßnahmen oder Visionen. Diese Vorgaben sollten idealerweise bereits Erkenntnisse aus einer kritischen Auseinandersetzung mit ML und der Ableitung eines geeigneten strategischen Vorgehens für das jeweilige Unternehmen berücksichtigen (siehe AF Strategische Vorgaben). Aufgrund damit verbundener Veränderungen ist auch die strategische Passung der Anwendungen rollierend zu überprüfen. Die Realisierung dieser Forderung soll dazu führen, dass nur strategisch relevante Anwendungen umgesetzt und betrieben werden, sodass sowohl eine Harmonisierung mit anderen langfristigen Vorhaben als auch eine Unterstützung der Anwendungen durch die Unternehmensführung sichergestellt ist, was für die Bereitstellung notwendiger Ressourcen von hoher Bedeutung ist. Bei den bisherigen ML-Anwendungen fehlte diese strategische Relevanz häufig, insbesondere im Falle einer Umsetzung durch die jeweiligen logistischen Fachbereiche. Den Projekten stehen dadurch häufig nach Realisierung eines prototypischen Systems keine weiteren Finanzierungsmöglichkeiten für eine Skalierung zur Verfügung.

6.3.10 Compliance

Der Einsatz von ML-Anwendungen im Logistikmanagement muss **rechtskonform und verantwortungsvoll** erfolgen, wofür bereits bei der Entwicklung relevante rechtliche und ethische Vorgaben zu berücksichtigen sind. Hierbei kann es sich um verbindliche Regeln, aber auch

um freiwillige Werte handeln, die entweder unternehmensspezifisch, z. B. in Form von Betriebsvereinbarungen und Verhaltenskodexen, oder unternehmensübergreifend festgelegt sind. Im Kontext von ML zählen dazu in erster Linie Vorgaben zur Datensicherheit und zum Datenschutz, welche u. a. den Umgang mit sensiblen Daten regeln, z. B. die DSGVO und das BDSG (siehe Kapitel 4.4.2). Hierzu muss sichergestellt werden, dass sich nach der Verarbeitung der Daten in den ML-Modellen keine personengebundenen Informationen für Dritte ableiten lassen. Auch sind Vorgaben zur systemseitigen Übergabe von Entscheidungsumfängen zu berücksichtigen, welche den Einsatz in bestimmten Anwendungsbereichen einschränken oder besondere Anforderungen an die Nachvollziehbarkeit stellen. Neben der entwicklungsseitigen Berücksichtigung sind zudem geeignete organisatorische Voraussetzungen in den Unternehmen zu schaffen, welche eine regelmäßige Kontrolle der Konformität sowie die Vorgabe unternehmensbezogener Regeln und Werte ermöglichen (siehe AF Governance). Rechtliche Vorgaben werden im Rahmen des produktiven Betriebs der gegenwärtigen ML-Anwendungen größtenteils eingehalten. Jedoch erfolgt dies in den wenigsten Fällen „by Design“, sondern erst durch nachträgliche entwicklungsseitige Anpassungen. Ethische Kriterien werden dagegen bisher vernachlässigt, was mit der vorherrschenden **Fokussierung auf die Ergebnisqualität** der Anwendungen sowie mit der fehlenden Verbindlichkeit und Eindeutigkeit der entsprechenden Vorgaben begründet wird.

6.4 Umfeldeigenschaften

Neben den Systemeigenschaften wurden auch **14 Eigenschaften** für das Umfeld von ML-Anwendungen ermittelt, welche ebenfalls für einen erfolgreichen Einsatz von ML-Anwendungen im Logistikmanagement vorliegen müssen. Die Eigenschaften werden im vorliegenden Subkapitel charakterisiert und sind vorab in Form einer präzisen Anforderungsformulierung in Tabelle 18 zusammengefasst.

Eigenschaft	Kurzbeschreibung
Datenverfügbarkeit	Es müssen sowohl Vergangenheitsdaten über einen längeren Zeitraum als auch Echtzeitdaten vorhanden und aus den entsprechenden IT-Systemen bereitstellbar sein.
Datenqualität	Die Daten müssen in einer hohen Qualität vorhanden sein, insbesondere durch eine automatisierte Erfassung und standardisierte Datenformate.
IT-Vernetzung	Es muss eine flächendeckende Anbindung der ML-Anwendungen an andere IT-Systeme zum Austausch der Input-Daten und der Ergebnisse vorhanden sein.
IT-Performance	Es muss eine IT-Infrastruktur vorhanden sein, die dem Leistungsbedarf von ML-Anwendungen Rechnung trägt.
Strategische Vorgaben	Es muss eine durch die Unternehmensführung initiierte Strategie oder Vision zum langfristigen Umgang mit ML vorhanden sein, die u. a. die Ziele und Auswirkungen aufzeigt.
Standardprozesse	Es müssen klar definierte Prozesse und Strukturen zur Auswahl und Umsetzung von ML-Anwendungen vorhanden sein.

Komplexitätsbeherrschung	Die Zielstellungen bei der Umsetzung der ML-Anwendungen müssen realistisch umsetzbar sein.
Akzeptanz	Bei den beteiligten Mitarbeitern muss eine positive Einstellung gegenüber dem Einsatz von ML vorhanden sein.
Transparenz	Es muss ein einheitliches Verständnis zu spezifischen Zielen sowie zum Nutzen und Wirkungsbereich der jeweiligen ML-Anwendungen vorhanden sein.
Interdisziplinäre Kooperation	Alle direkten und indirekten Stakeholder müssen (frühzeitig) bei der Umsetzung der ML-Anwendungen involviert werden, u. a. die Nutzer und der Betriebsrat.
Systemdenken	Es muss eine Kultur der kooperativen Zusammenarbeit über Abteilungs- und Unternehmensgrenzen vorhanden sein, die einem Bereichs- bzw. Inseldenken entgegenwirkt.
Personal und Finanzen	Es müssen zusätzliche finanzielle und personelle Ressourcen für die Entwicklung und den Betrieb der ML-Anwendungen vorhanden sein.
Kompetenz	Bei den Stakeholdern muss ein fachliches und methodisches Grundwissen zu ML vorhanden sein, v. a. zu Funktionsweisen, Potenzialen und Grenzen.
Governance	Es müssen klar definierte rechtliche und ethische Richtlinien zum unternehmensinternen und -übergreifenden Umgang mit ML-Anwendungen vorhanden sein.

Tabelle 18: Umfeldeigenschaften – Anforderungspräzisierung

6.4.1 Datenverfügbarkeit

Als technisch essenzielle Voraussetzung müssen **relevante Daten** zum jeweiligen Anwendungsfall für die Umsetzung von ML-Anwendungen verfügbar sein. Während die benötigten Daten im Rahmen der Entwicklung einmalig für einen historischen Zeitraum bezogen werden können, ist für den Betrieb und das damit verbundene Re-Training der Anwendungen ein kontinuierlicher Zugang zu den Daten sicherzustellen. Dafür müssen zum einen Speichermöglichkeiten vorhanden sein, welche die historischen Daten zu relevanten Bezugssystemen, z. B. zu bestimmten Objekten, Prozessen und Netzwerken, über einen längeren Zeitraum vorhalten (siehe AF IT-Performance). Zum anderen bedarf es einer Bereitstellung von aktuellen Daten, oft in Echtzeit, wozu eine automatische Übertragung benötigt wird (siehe AF IT-Vernetzung). Der genaue Datenbedarf hinsichtlich des Volumens und der Geschwindigkeit, d. h. der zeitliche Abstand zwischen den realen Ereignissen und der systemseitigen Verfügbarkeit, ist dabei abhängig von der Gestaltung der jeweiligen Anwendung bzw. der zugrundeliegenden ML-Modelle. Abgesehen von einigen Lerntypen bzw. -verfahren, wie dem Reinforcement Learning, kann aber grundsätzlich von einer größeren benötigten Datenmenge ausgegangen werden. Die Daten sollten zudem für die Entwicklung möglichst in Rohform vorliegen.

Für Anwendungsfälle im Logistikmanagement ist festzustellen, dass die Daten aufgrund der logistischen Querschnittsfunktion häufig in unterschiedlichen Quellsystemen vorliegen – sowohl innerhalb als auch außerhalb der jeweiligen Unternehmen. Diese **dezentrale Gestaltung der IT-Systemlandschaft** erschwert die Einbindung der relevanten Daten, insbesondere für eine permanente Bereitstellung im Betrieb. Demnach lassen sich vielfältige „formelle“ bzw. organisatorische Barrieren beobachten, die u. a. auf wettbewerbsbezogene oder rechtliche Gründe, z. B. im Falle von personenbezogenen Daten, aber auch auf Bereichsegoismen und

ein damit verbundenes Inseldenzen zurückgehen (siehe AF Systemdenken). Diese Barrieren treten insbesondere im Falle von benötigten Daten von anderen Unternehmen und Institutionen auf, aber auch bei Bereichen des eigenen Unternehmens, welche z. B. anderen Profitcentern angehören oder grundsätzlich eine restriktive Datenpolitik verfolgen, und führen im übertragenen Sinne zur **Bildung von „Datensilos“**. Entsprechend der Unsicherheit über den Datenzugang und dem damit verbundenen Aufwand wird eine zusätzliche Fokussierung auf die Sicherstellung der Verfügbarkeit dieser „externen“ Daten gefordert. Darüber hinaus lassen sich auch verschiedene technische Barrieren bei der Datenbereitstellung feststellen, die u. a. in Verbindung mit einer aufwendigen Extraktion der benötigten Daten stehen.

Die Verfügbarkeit relevanter Daten wird für die Anwendungsfälle im Logistikmanagement sehr unterschiedlich bewertet. Grundsätzlich ist jedoch festzustellen, dass zu produktionsnahen Prozessen tendenziell mehr Daten existieren als z. B. bei Transportprozessen, da letztere häufig einen vergleichsweise geringen Digitalisierungsgrad aufweisen, was sich u. a. in einer mündlichen oder mailbasierten Kommunikation sowie in manuellen Planungsaktivitäten äußert. Auch lässt sich in vielen Fällen beobachten, dass die Daten zu bestimmten Systemen nur für gegenwärtige Ereignisse oder einen **kurzen historischen Zeitraum** vorliegen, da sie entweder grundsätzlich nicht gespeichert oder in regelmäßigen Abständen in Form eines Data-Housekeepings gelöscht werden. Dies wird mit beschränkten Speicherkapazitäten sowie mit einem bisherigen Fokus auf den Austausch und die Auswertung von Echtzeitdaten begründet.

6.4.2 Datenqualität

Für die verfügbaren Daten wird zusätzlich eine hohe Qualität gefordert. Dies begründet sich zum einen durch den unmittelbaren Zusammenhang mit der Ergebnisqualität der ML-Anwendungen. Demnach führt eine Abweichung der Informationen in den Daten von realen Phänomenen zu ungeeigneten Ergebnissen, was auch als „*Garbage in, Gargabe out*“ bezeichnet wird. Zum anderen hat die Datenqualität hohe Auswirkungen auf den manuellen Aufwand und die benötigte Rechenleistung zur Auf- und Verarbeitung der Daten. Für die **Sicherstellung einer hohen Datenqualität** werden geeignete Maßnahmen gefordert, die u. a. eine automatisierte Datenerhebung und eine Standardisierung von Datenformaten umfassen. Analog zur Datenmenge ist jedoch festzustellen, dass die benötigte Qualität von der jeweils gewählten Modellkonfiguration abhängt, da bspw. bestimmte Lernverfahren vergleichsweise besser mit Rauschen in den Daten umgehen können (siehe Kapitel 2.4.3.2).

Die Qualität von Daten zu Anwendungsfällen im Logistikmanagement wird ebenfalls als sehr unterschiedlich beschrieben, wobei jedoch tendenziell eine geringere Ausprägung bei Logistikprozessen im Vergleich zu Daten in anderen Bereichen festzustellen ist, was u. a. mit der manuellen und nicht standardisierten Erfassung vieler Daten begründet wird. Die höchste Qualität wird kommerziell und rechtlich relevanten Daten attestiert, z. B. für eine Rückverfolgung von Produktionschargen. Grundsätzlich ist jedoch festzuhalten, dass die meisten in der Praxis verfügbaren Daten keine geeignete Qualität für deren direkte Verwendung bei der Entwicklung

von ML-Anwendungen aufweisen. Stattdessen zeigen sich unterschiedliche **inhaltliche und syntaktische Defekte**, welche mittels folgender Merkmale zusammengefasst werden können:

- Genauigkeit: Die Daten stimmen nicht mit der Realität überein, da sie bspw. falsche Zeitstempel oder Auftragsnummern enthalten.
- Vollständigkeit: Die Daten liegen unvollständig vor, da sie bspw. nur einen Teilzeitraum, bestimmte Relationen oder bestimmte Aufträge abdecken.
- Einzigartigkeit: In den Datensätzen liegen redundante Informationen vor.
- Konsistenz: Die Daten liegen syntaktisch nicht standardisiert vor, sondern weisen bspw. Unterschiede bei den Datums- und Ortsangaben oder bei anderen physikalischen Größen auf, wie der Zeit und Länge. In den einzelnen Datensätzen bestehen inhaltlich Widersprüche, z. B. in Form unterschiedlicher Zeitstempel für ein Ereignis.
- Gültigkeit: Die Daten weisen Informationen auf, die entweder nicht für die Modellentwicklung relevant sind oder deren Bedeutung unklar ist.

6.4.3 IT-Vernetzung

Zur Einbindung der benötigten Daten in ML-Anwendungen muss ein technischer Zugang zu den jeweiligen Quellsystemen sowie zu den Zielsystemen, d. h. den „virtuellen Kunden“, bestehen. In beiden Fällen kann es sich sowohl um unternehmensinterne als auch um -externe Systeme handeln. Für eine **Interoperabilität** zwischen den Systemen wird die Realisierung von Schnittstellen mit einer hohen Ausfallsicherheit (siehe AF Verfügbarkeit) und einer geringen Latenz in Hinblick auf einen echtzeitfähigen Datenaustausch gefordert. Anstelle der Programmierung individueller Schnittstellen sollen dazu standardisierte Architekturen eingesetzt werden, welche gleichzeitig eine Skalierbarkeit der ML-Anwendungen und die damit verbundene Anbindung an weitere Quell- und Zielsysteme ermöglichen.

Für die Anwendungsfälle von ML im Logistikmanagement existiert eine Vielzahl unterschiedlicher IT-Systeme mit potenziell relevanten Daten. Diese Systeme sind in den letzten Jahrzehnten für die Übernahme dedizierter Funktionen – teilweise auch in Form einer „Schatten-IT“ – entstanden und untereinander oft nicht vernetzt. Demnach ist häufig auch kein Datenaustausch zu anderen Systemen vorgesehen. Zudem lassen sich bei vielen Dateneigentümern (Data Owner) Vorbehalte bei der Bereitstellung der Daten an Dritte beobachten, was zu der angesprochenen Ausprägung der Systeme im Sinne von „Datensilos“ führt. Zur Reduktion des Aufwands für die Überwindung dieser technischen und organisatorischen Barrieren bei der Beschaffung der benötigten Daten werden geeignete Maßnahmen gefordert.

6.4.4 IT-Performance

Für die Aufnahme, Aufbereitung, Speicherung und Verarbeitung der benötigten Daten zum Betrieb von ML-Anwendungen muss eine **leistungsfähige IT-Infrastruktur** vorhanden sein. Diese Forderung kann mit der Prämisse „*There's no AI (Artificial Intelligence) without IA*“

(*Information Architecture*)“ zusammengefasst werden und steht im Zusammenhang mit den teils hohen Datenmengen und komplexen Rechenoperationen von ML-Anwendungen bei der gleichzeitigen Realisierung einer geringen Latenz für die Ergebnisbereitstellung. Da die benötigten Leistungsanforderungen in Abhängigkeit der jeweiligen Anwendungen stark variieren können, wird zudem eine **Skalierbarkeit** der Rechner- und Speicherkapazitäten gefordert. Die aktuell in vielen Unternehmen genutzte Infrastruktur wird diesen Leistungs- und Flexibilitätsanforderungen jedoch nicht gerecht, sodass in mehreren Fällen für den Betrieb der ML-Anwendungen auf externe Cloud-Services mittels IaaS zurückgegriffen wird. Die Entwicklung erfolgt dagegen zumeist lokal, wozu die bestehenden Daten- und Rechenzentren an den jeweiligen Standorten der Unternehmen genutzt werden.

6.4.5 Strategische Vorgaben

Über die genannten technischen Voraussetzungen hinaus muss für den Einsatz von ML eine Strategie durch die Unternehmensführung entwickelt und kontinuierlich angepasst werden, welche – unter Berücksichtigung anderer langfristiger Maßnahmen – eine übergeordnete Zielsetzung im Sinne einer Vision sowie geeignete Anwendungsfälle vorgibt. Diese Forderung wurde mit den hohen Auswirkungen von ML für die Unternehmen begründet, welche sich sowohl auf wirtschaftliche Effekte, u. a. durch die Reduktion des Personalbedarfs, als auch auf die Veränderungen von Arbeitsabläufen beziehen. Vor diesem Hintergrund bedarf es u. a. strategischer Überlegungen zum angestrebten Autonomisierungsgrad und zur zukünftigen Rolle menschlicher Entscheidungsträger in den Unternehmen. Mit der Ausarbeitung einer Strategie soll eine vorausgehende **kritische Reflektion dieser Auswirkungen** sowie eine Ableitung von unternehmensbezogenen Potenzialen und Risiken gewährleistet werden. Durch die Ausrichtung aller ML-bezogenen Aktivitäten auf eine zentrale Zielsetzung werden zudem nur strategisch relevante und aufeinander abgestimmte Projekte umgesetzt, womit eine Nutzmaximierung beim Einsatz von ML assoziiert wird.

Entgegen dieser Forderung haben die meisten Unternehmen ML bzw. KI im Allgemeinen bisher nicht in ihren strategischen Planungen berücksichtigt. Es finden sich lediglich Strategien oder Visionen zur **Umsetzung der digitalen Transformation** – häufig im Kontext von Industrie 4.0. Eine dezidierte Auseinandersetzung mit der strategischen Bedeutung von ML und die Ableitung eines geeigneten Vorgehens, einschließlich der Vorgabe von Anwendungsfällen, hat jedoch in den wenigsten dieser Fälle stattgefunden. Stattdessen agieren die einzelnen ML-Projekte losgelöst von zentralen Vorgaben und abseits einer übergreifenden Koordination.

6.4.6 Standardprozesse

Für die Umsetzung von ML-Anwendungen werden definierte Abläufe in den Unternehmen gefordert, welche verschiedene Ausprägungen von Anwendungen abdecken und als **Standardprozesse für alle ML-Projekte** fungieren. Diese Vorgaben sollen nicht nur die Aktivitäten der Entwicklung berücksichtigen, sondern auch die betriebliche Einführung der Systeme sowie

v. a. eine vorausgehende **Auswahl geeigneter Anwendungsfälle**. Neben der Darstellung eines funktionalen Ablaufs wird gefordert, dass diese Prozesse auch Informationen zu organisatorischen Strukturen sowie unterstützende Instrumente berücksichtigen, wie die Vorgabe von Verantwortlichkeiten und Kriterien für die Auswahl von Anwendungsfällen. Dies soll insgesamt eine unnötige Beanspruchung von Ressourcen, lange Entwicklungsdauern und technische Schulden in Folge einer eingeschränkten Skalierbarkeit der Anwendungen vermeiden.

Die bisherigen Ansätze zur Auswahl von ML-Anwendungen in der logistischen Praxis stehen im Zusammenhang mit dem jeweiligen Impuls zum Einsatz der Technologie. Hierzu können zwei wesentliche Ausprägungen unterschieden werden. In den meisten Fällen lässt sich ein **Technologie-Push** beobachten, bei dem die Nutzung von ML vordergründig einer experimentellen Erprobung der Technologie dient. Vor diesem Hintergrund erfolgt die Auswahl der Anwendungsfälle auch weniger zur Lösung zentraler betrieblicher Probleme, sondern eher als Reaktion auf den Hype der Technologie und zur „Vermarktung“ inner- oder außerhalb der Organisation. Daher werden in diesem Zusammenhang häufig prototypische Systeme angestrebt, teilweise auch in Form von **Leuchtturminitiativen**. Die jeweiligen Projekte werden zu meist von Innovationseinheiten in den Unternehmen verantwortet, wie dem Business Development oder Digitalisierungsabteilungen, wobei es sich in größeren Unternehmen auch um dedizierte Organisationseinheiten für die Entwicklung neuer Produkte und Geschäftsmodelle („Labs“) handeln kann, welche teilweise als separate Gesellschaften, entkoppelt vom eigentlichen Betrieb der Unternehmen agieren. Dieser Ansatz führt dazu, dass viele der resultierenden Anwendungen **keinen Bezug zu einem relevanten Problem** des Unternehmens aufweisen sowie aufgrund ihrer angestrebten Funktion zur experimentellen Erprobung und der geforderten Umsetzungsgeschwindigkeit in ihrer Skalierbarkeit eingeschränkt sind.

Auf der anderen Seite bestehen auch Fälle, bei denen sich der Einsatz von ML aus einem konkreten Bedarf in Form eines relevanten Problems ergibt, welches mit dieser Technologie gelöst werden sollen. Im übertragenden Sinne kann hierbei von einem Market- bzw. **Technologie-Pull** gesprochen werden. Die jeweiligen Systeme werden dabei dediziert für einen Anwendungsfall entwickelt, wobei die hierzu korrespondierenden Process Owner in Form der logistischen Fachbereiche die Verantwortung für die Umsetzung tragen. Dies erfolgt entweder im Sinne eines zentral genehmigten Citizen-Developer-Ansatzes oder in Form von **U-Boot-Projekten**, bei denen keine vorherige Abstimmung mit Zentralfunktionen des Unternehmens stattfindet. Hierdurch entstehen häufig Insellösungen in Form einer „Schatten-IT“ mit ebenfalls sehr **eingeschränkten Skalierungsmöglichkeiten**. In Ermangelung einer strategischen Bedeutung der adressierten Probleme erhalten die Anwendungen im Nachhinein zudem häufig keine ausreichende Unterstützung durch die Unternehmensführung, weshalb eine weitere Finanzierung ausbleibt und damit eine Überführung in produktive Systeme oder auf weitere Anwendungsfälle scheitert.

Entgegen der genannten Forderung lässt sich in beiden Fällen weder für die Auswahl noch für die Umsetzung der jeweiligen ML-Anwendungen eine Nutzung standardisierter Prozesse feststellen. Vielmehr wird das jeweilige Vorgehen für jede Anwendung bzw. jedes Projekt individuell gewählt, was zum Großteil zu sehr **unsystematischen Abläufen** mit teils hohen Ineffizienzen und dem Verbleib vieler Systeme in einem Prototypenstadium führt. Lediglich für die Entwicklungsaktivitäten wird vereinzelt auf Referenzmodelle zurückgegriffen, welche den jeweiligen Projektteams von anderen datenbasierten Vorhaben bekannt sind, wie der CRISP-DM, ohne dass jedoch ML-Spezifika vorgegeben werden.

6.4.7 Komplexitätsbeherrschung

Zusätzlich zur zuvor dargestellten Forderung eines standardisierten Prozesses müssen Voraussetzungen geschaffen werden, welche die mit der Umsetzung von ML-Anwendungen einhergehende Komplexität eindämmen. Dazu wird die **Vorgabe realistischer Zielstellungen für die ML-Projekte** gefordert, welche neben einer Fortschrittskontrolle auch eine zweckmäßige Zerlegung des entwicklungsseitigen Gesamtproblems ermöglichen. Hierbei soll initial ein Fokus auf kritische Komponenten der angestrebten Anwendungen gelegt werden, wobei es sich entsprechend der Neuartigkeit im Wesentlichen um die Realisierung der ML-Modelle und der damit verbundenen Funktionen handelt. Diese Forderung steht nicht im Widerspruch zur kontinuierlichen Betrachtung des Gesamtsystems (siehe AF Systemdenken), sondern soll vielmehr zu einem **inkrementellen Vorgehen** führen.

Die Notwendigkeit einer Komplexitätsreduzierung steht im Zusammenhang mit der Unsicherheit über die technische Realisierbarkeit von ML-Anwendungen, welche insbesondere bei neuen Problemstellungen besonders stark ausgeprägt ist. Demnach sind für viele Anwendungsfälle im Logistikmanagement sowohl innerhalb der jeweiligen Unternehmen als auch im Kontext des gesamten Forschungsstands keine nutzbaren Vorarbeiten vorzufinden. Darüber hinaus erfordert jeder Anwendungsfall aufgrund des problem- bzw. datenspezifischen Verhaltens der Lernverfahren und der damit verbundenen Modellkonfigurationen eine individuelle Lösung, welche nur durch eine direkte Implementierung und Testung verschiedener Ansätze identifiziert werden kann. Dies führt insgesamt zu einem **experimentellen Vorgehen** nach dem Trial-and-Error-Prinzip, welches bei der Identifikation neuer Ansätze für eine Verbesserung, z. B. durch den Zugang weiterer Daten, stets eine Ausführung mehrerer sequenzieller Tätigkeiten erfordert, die einen nicht unerheblichen Aufwand induzieren.

Entsprechend der fehlenden Möglichkeit einer analytischen Herleitung eines optimalen Lösungsweges ist zu beobachten, dass sich die mit der Entwicklung betrauten Mitarbeiter, insbesondere die Data Scientists, häufig in experimentellen Tätigkeiten „verlieren“, indem sie möglichst viele unterschiedliche Modellkonfigurationen, Lernverfahren, Merkmale, Daten o. ä. erproben, um nahezu „perfekte“ Lösungen – auch für eher sekundäre Teilprobleme – zu ge-

nerieren. Dieses Phänomen wird allgemein im Kontext der Softwareentwicklung als **Premature Optimization** bezeichnet⁶⁵⁹ und führt teilweise zu langen Entwicklungszeiten sowie zu einer eingeschränkten Praxistauglichkeit der resultierenden Anwendungen, da sich diese entweder vom eigentlich zu lösenden Problem entfernt haben oder nicht realisierbare Anforderungen implizieren, wie z. B. einen zu hohen Leistungs- oder Datenbedarf. Entsprechend des wissenschaftlichen Interesses der involvierten Mitarbeiter werden auch mitunter Erkenntnisse zu Einschränkungen bezüglich der Realisierbarkeit von angedachten Lösungswegen und Funktionen ignoriert. Dies betrifft auch eine etwaige Vorteilhaftigkeit anderer technischer Ansätze abseits von ML, die für das jeweilige Gesamt- oder für Teilprobleme bessere oder vergleichbare Ergebnisse, jedoch mit einem geringeren Aufwand ermöglichen würden, sodass eine unnötige Komplexitätserhöhung (**Over-Engineering**) entsteht. Die genannten Probleme werden bei der aktuellen Entwicklung von ML-Anwendungen oft zu spät erkannt – teilweise erst bei der Fertigstellung einer prototypischen Lösung. Als weiterer Grund wurden sehr eingeschränkte Möglichkeiten für ein Controlling der ML-Projekte genannt, was auch im Zusammenhang mit dem Fehlen klar definierter und realistischer Zielstellungen sowie mit der einseitigen Beschränkung auf technische Zielgrößen steht (siehe AF Business Case).

6.4.8 Akzeptanz

Bei den Organisationsmitgliedern muss eine **positive Einstellung** gegenüber dem Einsatz von ML vorhanden sein, um einer fehlenden Unterstützung oder gar einer vollkommenen Ablehnung entgegenzuwirken. Dies betrifft zuvorderst die designierten Nutzer, welche durch ihr Verhalten die Adoption von Technologien direkt beeinflussen. Darüber hinaus muss auch bei allen weiteren betroffenen Mitarbeitern, u. a. den Führungskräften, Arbeitnehmervertretern und Dateneigentümern, eine Akzeptanz sichergestellt werden, um u. a. deren Mitwirkung bei der Identifikation und Umsetzung von Anwendungsfällen zu ermöglichen. Hierzu ist zu Beginn eine „kritische Masse“ an Mitarbeitern zu gewinnen, welche den Technologieeinsatz aktiv fördern und auf andere Personen positiv einwirken.

Die jeweilige Einstellung der Organisationsmitglieder gegenüber ML resultiert aus der Konformität der einzelnen Anwendungen in Bezug auf die individuellen Anforderungen. Über diese rationale Sichtweise hinaus existiert aber auch eine subjektive Wahrnehmung, welche im Kontext von ML bzw. KI häufig eher negativ ausgeprägt ist. Dies geht auf eine grundsätzliche Präferenz von menschlichen Entscheidungen zurück – auch im Falle des Vorliegens besserer systemseitiger Ergebnisse. Dieses Phänomen wird in der Verhaltensforschung als **Algorithmus-Aversion** beschrieben⁶⁶⁰ und ist aus Sicht der befragten Unternehmen in der Logistik vergleichsweise stark ausgeprägt. Es äußert sich in höheren Anforderungen an die Zuverlässigkeit von Systemen bei einer gleichzeitig stärkeren Sensitivität gegenüber systemseitigen Fehlern, welche beim Auftreten zur Ausbildung eines Misstrauens bei den Menschen führen.

⁶⁵⁹ Vgl. Knuth (1974), S. 671

⁶⁶⁰ Vgl. Dietvorst et al. (2015), S. 114

Im Kontext von ML wird dieses Phänomen zusätzlich durch den **Black-Box-Charakter** und die damit verbundene Unkenntnis über den systemseitigen Lösungsweg von ML-Anwendungen verstärkt. Zudem besteht bei vielen Mitarbeitern eine Unsicherheit hinsichtlich der eigenen Vorteile aus dem Einsatz von ML. Oftmals wird sogar von einer Verschlechterung der eigenen Arbeitsbedingungen ausgegangen, was in Verbindung mit dem Autonomisierungspotenzial von ML steht, welches die Menschen als Gefahr wahrnehmen. Die damit verbundenen Ängste reichen von einer aufgabenbezogenen Bevormundung der Menschen durch die Systeme über den **Verlust der Arbeit** bis hin zum Eintreten apokalyptischer Zukunftsszenarien in Form einer Dominanz von humanoiden Systemen über die Menschen. Auf der anderen Seite führen diese Zukunftsszenarien bei einigen Mitarbeitern auch zu großen, teilweise nicht zu realisierbaren Erwartungen an ML. Diese positive Wahrnehmung kann im Falle einer Nichterfüllung zu einer Enttäuschung und damit wiederum zu einer Ablehnung führen.

6.4.9 Transparenz

Es wird eine **proaktive Kommunikation** zum jeweils angestrebten ML-Einsatz in den Unternehmen durch die Führungskräfte gefordert, was langfristig zu einer diesbezüglichen „Kultur der Offenheit“ in den Organisationen führen soll. In erster Linie handelt sich dabei um Informationen zu den Anwendungen, welche den involvierten Stakeholdern zu vermitteln sind, zu denen insbesondere die mit der Entwicklung betrauten Mitarbeiter, die späteren Nutzer sowie die Arbeitnehmervertreter, aber auch die Eigentümer der benötigten Daten und weitere Wissensträger zählen. Unter Berücksichtigung der Compliance kann dies im Falle von unternehmensübergreifenden Anwendungen zudem externe Instanzen betreffen. Diesem Personenkreis sind die Ziele der jeweiligen Anwendung darzulegen, wozu neben den angestrebten betriebswirtschaftlichen Potenzialen v. a. die prozessualen Veränderungen und die damit verbundenen Auswirkungen für die Mitarbeiter zählen, z. B. in Form einer veränderten Arbeitsorganisation zwischen den Menschen und Systemen. Neben intendierten Verbesserungen sind dabei auch etwaige negative Auswirkungen für die Arbeitnehmer zu benennen, z. B. eine angestrebte Reduktion von Arbeitsplätzen. Zudem sind in diesem Zusammenhang die Grenzen der Anwendungen aufzuzeigen, wozu neben technischen Limitationen, z. B. in Hinblick auf die realisierbare Prognosegüte, auch die Begrenzung des jeweiligen Anwendungsbereiches entsprechend der „maximalen“ Skalierung zählt. Neben den genannten anwendungsbezogenen Informationen wird zusätzlich eine unternehmensweite Kommunikation der jeweils übergreifenden Zielsetzungen zum Einsatz von ML gefordert, was eine etwaig bestehende Vision, die angestrebten Auswirkungen für das jeweilige Unternehmen sowie die geplanten Anwendungen umfasst, wobei für Letzteres zusätzlich der jeweilige Zusammenhang zur Realisierung der Vision aufzuzeigen ist.

Die Kommunikation der genannten Informationen soll ein gemeinsames Verständnis bei den Stakeholdern zu den Zielen der einzelnen ML-Anwendungen sicherstellen. Anders als bei den

bisherigen ML-Projekten, für die häufig vorab **keine eindeutigen technischen und betriebswirtschaftlichen Ziele** bestanden, soll dadurch eine kontinuierliche Fortschrittskontrolle ermöglicht werden, sodass Abweichungen vom eigentlich zu lösenden Problem möglichst schnell erkannt werden. Gleichzeitig soll dadurch bei allen Organisationsmitgliedern ein Bewusstsein für die Bedeutung von ML und der einzelnen Anwendungen für das jeweilige Unternehmen geschaffen werden, was sich positiv auf deren Akzeptanz und damit auf deren Mitwirkung bei der Umsetzung und dem Einsatz der Anwendungen auswirkt. Aktuell lässt sich jedoch nur selten eine projektübergreifende Kommunikation von ML-Aktivitäten erkennen. Die damit verbundene Unkenntnis der Organisationsmitglieder zu den jeweiligen Anwendungen und deren Bedeutung für das Unternehmen äußert sich in verschiedenen Widerständen, u. a. in Bezug auf die Bereitstellung von benötigten Daten.

6.4.10 Interdisziplinäre Kooperation

Für die effektive und effiziente Umsetzung von ML-Anwendungen werden organisatorische Strukturen und Regeln in den Unternehmen gefordert, welche eine frühzeitige und hinsichtlich der Intensität variierende Einbindung von Personen mit unterschiedlichen Kompetenzen und Aufgaben aus verschiedenen Organisationseinheiten ermöglichen. Bei den benötigten Mitarbeitern handelt es sich zum einen um mehrere Vertreter aus dem erweiterten IT-Umfeld mit **unterschiedlichen Qualifikationsprofilen**, welche für verschiedene Aktivitäten entlang des Umsetzungsprozesses eingesetzt werden müssen. Neben „klassischen“ Entwicklern umfasst dies Fachkräfte zur Aufbereitung und Analyse von Daten sowie zur Entwicklung der ML-Modelle. Zu weiteren einzubindenden Personen gehören Wissensträger zu den adressierten Prozessen und Daten. Aufgrund des prozessübergreifenden Charakters vieler ML-Anwendungen im Logistikmanagement handelt es sich dabei zudem häufig um Vertreter aus verschiedenen Organisationseinheiten, die auch fallweise anderen Unternehmen angehören können. Eine wichtige Instanz im Umsetzungsprozess sollen zudem **Vertreter der späteren Nutzergemeinschaft** bilden, wozu neben den designierten Nutzern auch übergeordnete Interessenvertreter, z. B. in Form eines Betriebsrates, zählen, welche u. a. Anforderungen hinsichtlich des Umgangs mit personengebundenen Daten und des Einsatzes der Systeme zur Verbesserung der Arbeitsbedingungen geltend machen sollen.

Viele Industrieunternehmen verfügen gegenwärtig über eine Linienorganisation, welche sich durch eine **funktionale Strukturierung** auszeichnet. Dies betrifft auf übergeordneter Ebene eine Segmentierung in unterschiedliche Funktionsbereiche sowie innerhalb dieser einzelnen Bereiche einer zusätzlichen Unterteilung in funktionsorientierte Abteilungen und Teams, in denen Mitarbeiter mit ähnlichen Kompetenzen gebündelt werden. Im Falle des IT-Bereiches führt das u. a. zu einer organisatorischen Trennung von Mitarbeitern für die Entwicklung und den Betrieb von Anwendungen. Die hierarchischen und starren Strukturen dieser Organisationsform erzeugen zwar eine Stabilität in den Unternehmen, **erschweren allerdings eine flexible**

interdisziplinäre Zusammenarbeit und Kommunikation über Abteilung- und Bereichsgrenzen hinweg. Die bisherigen Projekte, welche als temporäre Organisationseinheiten zur Umsetzung von ML-Anwendungen gebildet werden, sind daher oft uneinheitlich und ungeeignet in die Gesamtorganisation eingebunden, was zu Problemen bei der Finanzierung, der Führungsverantwortung und der Zusammensetzung der Teams führt. Daher können nicht alle erforderlichen Mitarbeiter über die benötigte Zeit für die Projekte rekrutiert werden, sodass u. a. wichtige prozess- und datenseitige Wissensträger sowie notwendige IT-Fachkräfte nicht oder nur partiell für die Umsetzung der Anwendungen zur Verfügung stehen. Vertreter der Nutzergemeinschaft werden zudem häufig gar nicht oder zu spät eingebunden.

6.4.11 Systemdenken

Über die Schaffung organisatorischer Voraussetzungen hinaus wird eine Veränderung der Denkweisen der beteiligten Mitarbeiter gefordert, bei der anstatt der Verfolgung bereichsbezogener Perspektiven und Interessen das eigene Handeln einem Gesamtziel in Form der Umsetzung der jeweiligen ML-Anwendung und damit des Erreichens einer Verbesserung für das Unternehmen bzw. der gesamten Logistikkette untergeordnet wird. Dieses Systemdenken soll langfristig zu einer **Kultur der kooperativen Zusammenarbeit** über Abteilungs-, Funktionsbereichs- und Unternehmensgrenzen hinweg führen und erfordert zum einen die Vorgabe einer übergeordneten Zielstellung und eines gemeinsamen Nutzens (siehe AF Strategische Vorgaben). Zum anderen muss hierfür ein Bewusstsein über die Notwendigkeit einer Einbindung von verschiedenen unternehmensinternen und teilweise -externen Personen in den Umsetzungsprozess geschaffen werden. Dazu müssen die Stakeholder von Beginn an die zu realisierende **Anwendung als Gesamtsystem begreifen**, welches zur Lösung eines relevanten Problems beiträgt und dazu aus mehreren technischen Komponenten besteht, für deren Realisierung unterschiedliche Wissensträger und Kompetenzen erforderlich sind.

Ein ausgeprägtes Systemdenken bei der Umsetzung von ML-Anwendungen kann bisher nur in wenigen Fällen festgestellt werden. Stattdessen geht die funktionale Organisationsstruktur der Unternehmen oft mit der **Ausbildung von „Silos“ und einem Inseldenen** in den Unternehmen einher. Dies hemmt die kooperative Mitwirkung der benötigten Fachbereiche an den Projekten, u. a. zur Datenbereitstellung, und führt stattdessen zu einer Verfolgung von Partikularinteressen. Selbiges gilt für unternehmensübergreifende Projekte zur Realisierung von Anwendungen entlang der Wertschöpfungs- bzw. Logistikketten. Auch zeichnen sich die bestehenden ML-Projekte durch eine **Fokussierung auf entwicklungsseitige Aktivitäten** aus, welche die Umsetzung der jeweilige ML-Modelle in einem ausgewählten Bereich adressieren. Hierdurch bleiben die benötigten Voraussetzungen zur Gestaltung des Gesamtsystems, z. B. in Form des Zusammenwirkens mit anderen Komponenten, und zur Schaffung entsprechender Umfeldbedingungen, wie die Realisierung einer durchgehenden Datenverfügbarkeit für die Systeme, weitestgehend unberücksichtigt. Dies führt häufig zu hohen Aufwänden bei der

Überführung dieser Modelle in einen produktiven Betrieb und für die Nutzung in anderen Anwendungsfällen.

6.4.12 Personal und Finanzen

Für den Einsatz von ML müssen zusätzliche finanzielle Mittel in den Unternehmen bereitgestellt werden, welche zur Realisierung der Anwendungen und des benötigten Umfelds eingesetzt werden können. Neben den infrastrukturellen Voraussetzungen betrifft dies im besonderen Maße die **Finanzierung von Mitarbeitern**, welche die Entwicklung und den Betrieb der ML-Anwendungen verantworten. Diese Mitarbeiter sollen in den Unternehmen flexibel zur Verfügung stehen. Einige der benötigten Qualifikationsprofile, wie die Datenwissenschaftler und -ingenieure, weichen allerdings von den typischen Kompetenzen in Industrieunternehmen ab und müssen daher gezielt aufgebaut werden. Zudem sind der tatsächliche Personalbedarf und demzufolge auch die Kosten nur schwer kalkulierbar. Neben einer häufigen Unkenntnis der Unternehmen über das anzustrebende Anwendungsspektrum wird dies mit dem experimentellen Vorgehen bei der Umsetzung von ML-Anwendungen begründet. Zum Umgang mit dieser Unsicherheit fordern die Unternehmen entsprechende Risikopuffer bei der Festlegung des Budgets für die Finanzierung von ML-Projekten.

Abweichend dazu lässt sich gegenwärtig feststellen, dass die Fachkräfte für die Umsetzung von ML-Anwendungen in den Unternehmen nicht im benötigten Umfang zur Verfügung stehen. Auch ermöglicht ihre funktionale Einbindung in die Organisationsstruktur keinen flexiblen Einsatz in anderen Bereichen. Demnach sind die ML-spezifischen Fachkräfte häufig dedizierten **Innovationseinheiten zugeordnet**, welche primär die experimentelle Erprobung von ML durch die Umsetzung prototypischer Anwendungen anstreben (siehe AF Standardprozesse). Ein flächendeckender Einsatz von ML in den Unternehmen kann mit den Ressourcen und Budgets dieser Organisationseinheiten nicht realisiert werden. Auf der anderen Seite lässt sich auch beobachten, dass die logistischen Fachbereiche eigene Ressourcen zu **Umsetzung bereichsspezifischer Anwendungen** aufbauen, indem sie bestehende, größtenteils fachfremde Mitarbeiter qualifizieren. Infolge der Finanzierung dieser Mitarbeiter mittels bereichseigener Budgets und deren weiterer Einbindung in das Tagesgeschäft können sie ebenfalls nur bedingt in anderen Bereichen eingesetzt werden. Eine Verantwortung der ML-Projekte durch Mitarbeiter des jeweiligen IT-Bereichs erfolgt dagegen bisher nur vereinzelt. Stattdessen agiert die IT vordergründig als klassischer **interner Dienstleister** zur Lösung gemeldeter Probleme.

6.4.13 Kompetenz

Neben dem Bedarf an spezialisierten Fachkräften mit IT-affinen Qualifikationsprofilen für die Entwicklung und den Betrieb von ML-Anwendungen wird auch eine grundlegende **Sachkompetenz zu ML** bei allen übrigen Stakeholdern gefordert. Dazu müssen die jeweiligen Mitarbeiter über Grundkenntnisse zur Funktionsweise und zu Voraussetzungen von ML sowie zu den realisierbaren Potenzialen und bestehenden Grenzen verfügen. Hierdurch soll zum einen die

wahrgenommene Komplexität von ML und die damit oft assoziierte Gefahr (siehe AF Akzeptanz) reduziert werden. Demnach wird davon ausgegangen, dass die Mitarbeiter durch das vermittelte Wissen die Bedeutung der Technologie verstehen und eine realistische Erwartungshaltung entwickeln. Zum anderen sollen sie dadurch zur Identifikation geeigneter Anwendungsfälle und zum achtsamen Umgang mit Daten befähigt werden.

Als wichtige Zielgruppe für die Vermittlung dieser Kenntnisse werden die jeweiligen disziplinarischen und fachlichen Führungskräfte betrachtet, welche auf dieser Grundlage eine positive Einstellung zu ML entwickeln und den Adoptionsprozess aktiv unterstützen können. Zusätzlich werden sie zur Formulierung realistischer Zielstellungen und Projektplanungen für den Einsatz von ML in den Unternehmen befähigt. Auch auf den Nutzern der ML-Anwendungen soll ein besonderer Fokus liegen. In Ergänzung zur Vermittlung der genannten Kompetenzen müssen diese zusätzlich für die Zusammenarbeit mit den jeweiligen Anwendungen hinsichtlich deren Bedienung, Kontrolle und Verbesserung befähigt werden. Neben dem Verständnis über systemseitige Funktionen und Interaktionselemente, wie es auch bei konventionellen Anwendungen notwendig ist, bedarf es zusätzlicher rudimentärer **Kenntnisse über entwicklungsseitige Charakteristika**, um die Fähigkeiten und Grenzen sowie das Verhalten der jeweiligen Systeme verstehen zu können. Dies erfordert Wissen zur grundlegenden Funktionsweise der jeweiligen Modelle bzw. der verwendeten Lernverfahren sowie zu den einbezogenen Input-Daten und den darauf basierenden Features. Wie die Analyse des Umsetzungsstands in der Logistik zeigt, beschränkt sich die Kompetenzverteilung zu ML in den Unternehmen bisher auf die spezialisierten Fachkräfte. Dem Großteil der restlichen Organisationsmitglieder, sowohl im Bereich des Managements als auch auf operativer Ebene, fehlt dieses Wissen, was auch eine Ursache für die negative Einstellung vieler Mitarbeiter gegenüber ML darstellt.

6.4.14 Governance

Es müssen klar definierte Regeln und Werte vorhanden sein, welche den Einsatz von ML in den Unternehmen **aus rechtlicher und ethischer Sicht determinieren**. Diese Vorgaben sollen wichtige Fragestellungen zur Übertragung von Entscheidungsumfängen auf die Anwendungen abdecken, was u. a. die Zulässigkeit systemseitiger Entscheidungen, die damit verbundene juristische Verantwortung und Haftung sowie die Vermeidung eines unkontrollierten Systemverhaltens betrifft. Auch ist darüber hinaus die zukünftige Rolle von menschlichen Entscheidungsträgern in den Unternehmen zu betrachten. Bei der Festlegung etwaiger unternehmensspezifischer Richtlinien sollen bestehende Vorgaben durch den Gesetzgeber und andere öffentliche Institutionen auf nationaler und europäischer Ebene berücksichtigt werden, wobei es hierzu einer regelmäßigen Überprüfung bedarf.

Spezifische Vorgaben zur Nutzung von ML bzw. KI im Allgemeinen sind bisher nur vereinzelt in den Unternehmen vorzufinden. Bei einer erweiterten Betrachtung lassen sich jedoch in mehreren Unternehmen Richtlinien zum Umgang mit eigenen und externen Daten feststellen, welche unter dem Begriff der **Datenethik** (Data Governance) zusammengefasst werden und


ebenfalls für den Einsatz von ML relevant sind. Grundsätzlich wird die Erarbeitung von geeigneten Richtlinien als Aufgabe des Gesetzgebers angesehen, der aufgrund der branchenweiten Bedeutung einheitliche Vorgaben für die Unternehmen bereitstellen soll. Anders als bisher praktiziert, soll es sich hierbei weniger um grundsätzliche Regelungen als eher um Vorgaben für konkrete Anwendungsbereiche handeln.

6.5 Bewertung

Nach der Beschreibung der einzelnen Eigenschaften wird in diesem Subkapitel eine Quantifizierung ihrer Bedeutung sowie – im Falle der Qualitäts- und Umfeldeigenschaften – ihres gegenwärtigen Umsetzungsstandes vorgenommen. Diese Bewertung basiert auf den Ergebnissen der Onlinebefragung und stellt die Grundlage für eine abschließende Priorisierung der Eigenschaften zur Schwerpunktsetzung bei der Entwicklung des Gestaltungsansatzes dar.

6.5.1 Funktionen

Anhand der Bewertungen durch die befragten Logistikvertreter ist festzustellen, dass alle ermittelten Funktionen eine hohe Bedeutung für den erfolgreichen Einsatz von ML-Anwendungen im Logistikmanagement aufweisen (siehe Abbildung 63). Innerhalb der marginalen Unterschiede besteht eine etwas höhere Bedeutung für die **Lernfähigkeit** und **Auswirkungsermittlung** (4,1). Ersteres stellt aus Sicht der befragten Unternehmen den wichtigsten Vorteil gegenüber bisherigen Entscheidungstechniken dar, da die Systeme dazu befähigt werden, ihr Verhalten eigenständig zur Lösung veränderter Problemstellungen anzupassen. Es zeigt sich aber auch, dass bestehende ML-Anwendungen vielfach ohne ein regelmäßiges Re-Training, sondern eher als „statische“ Anwendung, eingesetzt werden, um bspw. einmalig Zusammenhänge für bestimmte Problemstellungen zu ermitteln. Entsprechend dieser Erfahrungen nehmen nicht alle Unternehmen die Lernfähigkeit als notwendige Funktion wahr. Eine etwas geringere Bedeutung weist die **Szenarienbildung** auf (4,0), welche – abseits eines autonomen Einsatzes der Anwendungen – durch die Bereitstellung mehrerer Ergebnisoptionen die Entscheidungsgrundlage für die Nutzer deutlich verbessern soll. Anhand eines Vergleichs dieser Ergebnisse kann auch deren Plausibilität bewertet werden, wodurch das Vertrauen in die Güte gesteigert wird. Für die **Entscheidungsfähigkeit** ist die vergleichsweise geringste Bedeutung festzustellen (3,9), was mit der Zweckmäßigkeit einer Abdeckung dieser Funktion durch andere Systeme in vielen Anwendungsfällen begründet wird. Demnach ist es aus Sicht mehrerer Unternehmen ausreichend, wenn bestimmte ML-Anwendungen ausschließlich vorgelagerte Aktivitäten von Entscheidungsprozessen zur Problemwahrnehmung oder Informationsbeschaffung ausführen, z. B. in Form einer Prognose, und die dabei erzielten Ergebnisse anderen Systemen oder den jeweiligen Nutzern zur Generierung geeigneter Aktionen bereitgestellt werden. Gleichzeitig wird aber auch zur Reduzierung der Systemkomplexität eine Integration der ML-basierten Funktionen in die Ausführungssysteme angestrebt.

Abbildung 63: Funktionen – Bewertung der Bedeutung⁶⁶¹

6.5.2 Qualitätseigenschaften

Für alle ermittelten Qualitätseigenschaften ist eine **hohe bis sehr hohe Bedeutung** in Bezug auf den erfolgreichen Einsatz von ML-Anwendungen im Logistikmanagement festzustellen (siehe Abbildung 64). Die Ausprägungen liegen in einem Intervall von 3,9 bis 4,8 und ergeben ein arithmetisches Mittel von 4,3 mit einer Standardabweichung von 0,32. Dieses Bedeutungs-niveau steht in starker Diskrepanz zum gegenwärtigen Umsetzungsstand der Eigenschaften bei den bisherigen ML-Anwendungen. Demnach weisen die einzelnen Qualitätseigenschaften nur einen **mäßig bis geringen Umsetzungsstand** auf. Die Ausprägungen liegen demnach in einem Intervall von 2,2 bis 3,4 mit einem arithmetischen Mittel von 2,9. Hieraus ergibt sich eine durchschnittliche Differenz von 1,5 zwischen beiden Bewertungsdimensionen.

Abbildung 64: Qualitätseigenschaften – absolute Bewertung⁶⁶²

⁶⁶¹ Eigene Darstellung

⁶⁶² Eigene Darstellung. Der Umsetzungsstand wurde anhand der Adopter ermittelt.

Die Systemeigenschaften mit der höchsten Bedeutung stehen in direkter Verbindung zur Ergebnisqualität. Zum einen muss durch die Ermittlung eines geeigneten Lösungsansatzes entwicklungsseitig sichergestellt werden, dass die Anwendungen in der Lage sind, **fehlerfreie Ergebnisse** zu ermitteln (4,7). Zum anderen muss eine Verfälschung der Ergebnisse durch einen **unbewussten oder bewussten Eingriff** von Dritten verhindert werden (4,8). Neben der Realisierung zuverlässiger und manipulationssicherer Anwendungen nimmt auch die Existenz von Mechanismen zur **Kontrolle der systemseitigen Ergebnisse** eine sehr hohe Bedeutung für die Unternehmen ein (4,5). Diese Relevanz der ergebnisseitigen Fehlerfreiheit steht im engen Zusammenhang zum angestrebten Einsatz der Anwendungen in (semi-)autonomen Szenarien. Zusätzlich wird die systemseitige **Konformität zu relevanten rechtlichen und ethischen Vorgaben** als sehr bedeutsam erachtet, um sowohl formale Voraussetzungen für den Einsatz in allen Anwendungsfällen zu erfüllen als auch emotionale Widerstände bei den Beteiligten abzubauen (4,6). Es wird auch ersichtlich, dass die einzelnen Anwendungen nicht nur die Anforderungen eines dedizierten Anwendungsfalls abdecken sollen. Vielmehr bedarf es einer **Skalierbarkeit**, d. h. der Möglichkeit zum Einsatz der Systeme für ein breites Anwendungsspektrum, was ebenfalls eine bedeutende Eigenschaft darstellt (4,4). Mit einer ebenfalls hohen, aber etwas nachrangigen Bedeutung wird die **Nachvollziehbarkeit** des Lösungsweges (4,1) und ein damit verbundenes „Tracking und Tracing“ des spezifischen **Lernprozesses** (4,3) betrachtet. Auch diese beiden Anforderungen werden mit einer Akzeptanzsteigerung assoziiert. Zusätzlich sollen dadurch die Eingriffsmöglichkeiten zur gezielten Optimierung der Anwendungen verbessert werden. Eine rechtliche Notwendigkeit nachvollziehbarer Lösungswege, wie sie bspw. im Bereich der Medizin vorzufinden ist, wird für das Logistikmanagement außerhalb des vollautonomen Szenarios nur für bestimmte Anwendungsfälle erwartet. Eine ebenfalls etwas geringere Bedeutung weist die **Verfügbarkeit** der Systeme auf (4,0), da bei einer Batch-Bereitstellung der Ergebnisse oder bei einer weiterhin starken Involvierung menschlicher Entscheidungsträger mögliche Systemausfälle partiell kompensiert werden können. Die vergleichsweise geringste Bedeutung, welche jedoch mit jeweils 3,9 – absolut betrachtet – weiterhin als hoch zu bezeichnen ist, weisen die **strategische Passung** und die frühzeitige Sicherstellung der **Wirtschaftlichkeit** der Anwendungen auf. Hier zeigt sich bei den befragten Unternehmen ein Dilemma zwischen der betriebswirtschaftlichen Notwendigkeit beider Anforderungen und der Steigerung des Innovationspotenzials durch die Gewährleistung größerer Freiheitsgrade für eine experimentelle Erprobung.

In Bezug auf den Umsetzungsstand der Systemeigenschaften bei den bestehenden ML-Anwendungen im Logistikmanagement ist für die **Compliance** die vergleichsweise höchste Ausprägung festzustellen (3,4). Zentrale rechtliche Vorgaben, wie die DSGVO oder unternehmensspezifische Betriebsvereinbarungen, werden demnach erfüllt. Die damit verbundene Prüfung erfolgt jedoch in den wenigsten Fällen während der Konzeption oder Entwicklung der Anwendungen, sondern erst nachgelagert. Zudem werden ethische Aspekte bisher vernachlässigt, was mit fehlenden Vorgaben begründet wird. Der zweithöchste Umsetzungsstand liegt für die **Manipulationssicherheit** vor. Im Falle von Anwendungen, welche auf einer externen

Cloud-Infrastruktur mittels IaaS betrieben werden, ist diese Eigenschaft vergleichsweise hoch ausgeprägt. Bei einem lokalen Betrieb zeigt sich allerdings ein gegenteiliges Bild, was insgesamt zu der mäßigen Bewertung von 3,2 führt. Diese Zweiteilung entsprechend der infrastrukturellen Grundlage gilt auch für die technische **Verfügbarkeit** der Anwendungen, deren Umsetzungsstand mit 2,8 bewertet wird. Für eine **Kontrollierbarkeit der Entscheidungsausführung und des Lernprozesses** sind bei mehreren Anwendungen bereits technische Komponenten integriert, welche eine automatische Bewertung der Ergebnisse entsprechend der definierten Güteintervalle sowie eine Ausgabe von entwicklungsseitigen Zusatzinformationen ermöglichen. Im Rahmen des bisherigen Einsatzes der Systeme als Entscheidungsunterstützung werden diese Maßnahmen auch als angemessen angesehen. Einem autonomen Betrieb werden sie jedoch nicht gerecht, sodass auch hier nur ein Umsetzungsstand von 3,1 erreicht wird. Für den **Strategic Fit** und die **Profitabilität** der Anwendungen lässt sich ebenfalls nur ein mäßiger Umsetzungsstand feststellen (2,8 bzw. 2,9), was auf die häufige Fokussierung einer experimentellen Erprobung von ML zurückgeht und mitunter zur Auswahl von strategisch und wirtschaftlich ungeeigneten Anwendungsfällen führt. Ein noch etwas geringerer Umsetzungsstand liegt bei der **Nachvollziehbarkeit** der Anwendungen vor, die entsprechend des derzeitigen Forschungsstands zu ML als systemimmanent bezeichnet werden kann. Das größte Manko zeigt sich für die **Skalierbarkeit** der Anwendungen (2,2). Bei einem Großteil der bestehenden Systeme handelt es sich demnach um Insellösungen, deren Nutzung für andere Anwendungsfälle mit einem sehr hohen Anpassungsaufwand verbunden ist – welcher teilweise einer Neuentwicklung gleichkommt. Diese eingeschränkte Adaptionmöglichkeit stellt auch einen Grund für den ebenfalls mäßigen Umsetzungsstand der **Zuverlässigkeit** dar (2,9). Auch wenn die bestehenden System für viele logistische Problemstellungen zufriedenstellende Lösungen generieren, fehlt es häufig an einer Übertragbarkeit dieser Ergebnisse auf andere Anwendungsfälle.

Bei einem Vergleich beider Bewertungsdimensionen zeigt sich, dass der Umsetzungsstand der Eigenschaften in keinem Fall der jeweiligen Bedeutung gerecht wird (siehe Abbildung 65). Die höchste Diskrepanz liegt dabei für die Skalierbarkeit der Anwendungen vor (Differenz von 2,2), gefolgt von der damit in Verbindung stehenden Zuverlässigkeit (1,8).




Abbildung 65: Qualitätseigenschaften – relative Bewertung⁶⁶³

6.5.3 Umfeldeigenschaften

Analog zu den Systemeigenschaften ist auch für alle ermittelten Umfeldeigenschaften eine **hohe bis sehr hohe Bedeutung** in Bezug auf den erfolgreichen Einsatz von ML-Anwendungen im Logistikmanagement festzustellen (siehe Abbildung 66). Die Ausprägungen liegen hierbei in einem Intervall von 3,6 bis 4,6 und weisen ebenfalls ein arithmetisches Mittel von 4,3 auf. Im Vergleich zu den Qualitätseigenschaften liegt jedoch eine geringere Standardabweichung von 0,2 vor, was insgesamt zu einem homogeneren Bedeutungslevel führt. Der gegenwärtige Umsetzungsstand, welcher für diese Eigenschaften in Bezug auf alle Unternehmen ermittelt wurde, zeigt ebenfalls **eine nur mäßige bis geringe Ausprägung**. Demnach liegen die Ausprägungen in einem Intervall von 1,9 bis 3,2 und ergeben ein arithmetisches Mittel von 2,7, welches damit etwas geringer als bei den Systemeigenschaften ausfällt. Hieraus ergibt sich auch eine etwas höhere durchschnittliche Differenz zwischen beiden Bewertungsdimensionen (1,6). Bei einer separaten Betrachtung ist für die Adopter ein marginal erhöhter Umsetzungsstand von 2,8 festzustellen.

⁶⁶³ Eigene Darstellung. Es ist die Abweichung zum jeweiligen Mittelwert dargestellt.



Abbildung 66: Umfeldeigenschaften – absolute Bewertung⁶⁶⁴

Die primär technischen Umfeldeigenschaften weisen insgesamt das höchste Bedeutungs-niveau auf. Dies trifft im besonderen Maße auf die datenseitigen Voraussetzungen zu, welche die Ergebnisqualität sowie die grundsätzliche Realisierbarkeit von ML-Anwendungen maßgeblich beeinflussen. Demnach muss eine **hohe Datenqualität** vorliegen (4,6), welche sich insbesondere durch eine informatorische Konformität zur Realität und durch geringe syntaktische Unterschiede der Daten auszeichnet. In diesem Zusammenhang wird auch eine automatische Erfassung der Daten gefordert. Zum anderen muss die **Verfügbarkeit von Vergangenheits- und Echtzeitdaten** sichergestellt werden (4,5), wobei auch festzustellen ist, dass die Anforderungen an beide Eigenschaften vom jeweiligen Anwendungsfall sowie der gewählten Modellgestaltung abhängig sind. Demnach existieren verschiedene Lernverfahren, die auch in Fällen mit einer geringeren Datenmenge und -qualität erfolgreich einsetzbar sind. Die datenseitigen Eigenschaften stehen in enger Verbindung mit der IT-Infrastruktur und den damit verbundenen Möglichkeiten zur Verarbeitung, Speicherung und kontinuierlichen Bereitstellung. Dies führt im Falle der **Leistungsfähigkeit der IT** zu einer ebenfalls sehr hohen Bedeutung (4,5), wobei neben einer hohen Rechen- und Speicherkapazität auch deren flexible Skalierbarkeit gefordert wird. Die hohe Bedeutung der **IT-Vernetzung** (4,3) bezieht sich auf die Sicherstellung einer Interoperabilität zwischen den ML-Anwendungen und den Ein- bzw. Ausgangssystemen.

⁶⁶⁴ Eigene Darstellung

Ein ähnlich hohes Bedeutungsniveau (4,2 bis 4,4) weist auch der Großteil der restlichen Umfelleigenschaften auf, welche primär organisatorische, rechtliche und ethische sowie strategische Anforderungen adressieren. Hierzu gehört die Sicherstellung einer geeigneten **Governance** für den Einsatz von ML-Anwendungen durch die Überführung bestehender sowie die Erstellung unternehmensspezifischer Regeln und Werte. Auch werden sowohl für die einzelnen Anwendungen bzw. die diesbezüglichen Projekte als auch für den langfristigen anwendungsübergreifenden Umgang mit ML verbindliche Ziele gefordert. Dies soll eine bewusste Gestaltung des Technologieeinsatzes sicherstellen und gleichzeitig die **Komplexität bei der Umsetzung** reduzieren. Der offenen **Kommunikation** dieser Zielsetzungen gegenüber allen Organisationsmitgliedern zur Förderung eines gemeinsamen Verständnisses über die Notwendigkeit von ML für das jeweilige Unternehmen wird ebenfalls eine hohe Bedeutung beigemessen. Die Realisierung dieser Voraussetzung soll sich positiv auf die **Akzeptanz** der Technologie bei den Mitarbeitern auswirken, was ebenfalls eine bedeutsame Anforderung darstellt. Für die Auswahl und Umsetzung von ML-Anwendungen wird zudem die Vorgabe eines **einheitlichen Vorgehens** gefordert, welches den Gesamtprozess abdeckt und zu einer systematischen Realisierung geeigneter Anwendungsfälle führt. Um im Rahmen dieses Vorgehens auch flexibel auf die benötigten Mitarbeiter mit den entsprechenden Qualifikationsprofilen – welche oft unterschiedlichen Fachbereichen angehören – zurückgreifen zu können, bedarf es zudem der Schaffung entsprechender organisatorischer Strukturen und Regeln. Gleichzeitig müssen entsprechende **Fachkräfte oder ein Budget** zu deren Rekrutierung oder Qualifizierung vorhanden sein. Neben diesen ab- und aufbauorganisatorischen Voraussetzungen wird auch der kulturellen Komponente eine hohe Bedeutung beigemessen. Demnach muss bei den an der Umsetzung von ML-Anwendungen beteiligten Personen, einschließlich der unternehmensexternen Instanzen, ein **Systemdenken** etabliert werden, was die kooperative Zusammenarbeit und ein Verständnis zu ML-Anwendungen als ein Gesamtsystem zur Lösung übergreifender Probleme fördert.

Eine vergleichsweise geringe, aber – absolut betrachtet – weiterhin hohe Bedeutung (3,6) weist die Forderung der Ausbildung einer ML-spezifischen **Kompetenz bei den jeweiligen Stakeholdern** auf, insbesondere bei den Führungskräften und Nutzern. Die Kompetenz kann sich demnach laut mehreren Unternehmen auf ein Grundverständnis zu Potenzialen und Grenzen von ML beschränken und ist z. B. bei kleineren Anwendungen, die Teil eines übergeordneten Gesamtsystems sind, nicht obligatorisch. Gleichzeitig wird aber auch auf die damit verbundene akzeptanzfördernde Wirkung im Sinne einer „Entmystifizierung“ von ML und die Möglichkeit der jeweiligen Mitarbeiter zur Identifikation von Anwendungsfällen hingewiesen. Bei einer gruppenspezifischen Betrachtung der Adopter ist festzustellen, dass neben dem weiterhin hohen Niveau der datenseitigen und infrastrukturellen Eigenschaften (4,4 bis 4,6) die Komplexitätsbeherrschung im Sinne einer Vorgabe klarer und realistischer Zielstellungen für den Umsetzungsprozess (4,5) sowie die Bereitstellung der dafür notwendigen personellen und finanziellen Ressourcen (4,6) eine vergleichsweise hohe Bewertung aufweist.

In Bezug auf den gegenwärtigen Umsetzungsstand der Umfeldeigenschaften ist für die **infrastrukturelle Leistungsfähigkeit** die höchste Ausprägung festzustellen. Dies geht erneut auf die Nutzung externer Cloud-Infrastruktur durch mehrere Unternehmen und deren damit verbundener Möglichkeit eines flexiblen Zugriffs auf höhere Rechen- und Speicherkapazitäten zurück. Dem stehen die lokalen Voraussetzungen bei den restlichen Unternehmen gegenüber, welche den hohen Leistungsanforderungen von ML oftmals nicht gerecht werden, sodass sich auch für diese Eigenschaft insgesamt ein nur mäßiger Umsetzungsstand von 3,2 ergibt. Dasselbe Bewertungsniveau liegt auch für die **Verfügbarkeit von Daten** vor, welche in einzelnen Anwendungsfällen bereits als angemessen bezeichnet werden kann. Grundsätzlich ist jedoch festzustellen, dass viele potenziell relevante Daten im logistischen Umfeld aufgrund einer manuellen Prozessausführung und Kommunikation nicht verfügbar sind. Auch ergeben sich im Falle vorliegender Daten oft technische oder organisatorische Barrieren für deren Beschaffung, insbesondere wenn es sich bei deren Eigentümern um verschiedene Fachbereiche, Profitcenter oder gar andere Unternehmen handelt. Diese Barrieren stehen im Zusammenhang mit der funktionalen Organisationsstruktur vieler Unternehmen, welche historisch zu einem Aufbau von „Silos“ bei der Arbeitsorganisation, aber auch bei den IT-Systemen geführt hat. Das spiegelt sich in dem mäßigen Umsetzungsstand für die geforderte **IT-Vernetzung** (2,9) sowie für die Realisierung eines **Systemdenkens** (2,7) und einer **interdisziplinären Kooperation** (2,5) wider. Demnach können die benötigten Mitarbeiter aus den einzelnen Fachbereichen oft nicht flexibel für die Umsetzung von ML-Projekten eingesetzt werden. Erschwerend kommt hinzu, dass in vielen Unternehmen keine ausreichenden **personellen und finanziellen Ressourcen** für die Umsetzung von ML-Anwendungen vorhanden sind, was sich auch im geringen Umsetzungsstand von 2,5 ausdrückt. Im Falle vorhandener Fachkräfte sind diese oft speziellen Innovationseinheiten, z. B. Entwicklungslaboren, zugeordnet, die nur begrenzt die Probleme aus den logistischen Fachbereichen abdecken können. Im Vergleich zur Verfügbarkeit werden der **Qualität der Daten** noch größere Defizite attestiert (2,9), die sich in inhaltlichen und syntaktischen Fehlern der Daten äußern und häufig auf eine manuelle Erfassung sowie ein fehlendes Bewusstsein für die Bedeutung von Daten zurückgehen.

Das Vorgehen für die **Auswahl und Umsetzung der Anwendungen** wird gegenwärtig zu meist projektspezifisch festgelegt, wobei nur im Falle der entwicklungsseitigen Aktivitäten teilweise auf Standardprozesse zurückgegriffen wird. Für den Gesamtprozess fehlen bisher entsprechende Vorgaben, was insgesamt zu einem eher unsystematischen Ablauf und damit zu einem Umsetzungsstand von 2,6 führt. Dies steht auch im Zusammenhang mit der oft fehlenden Festlegung klarer und v. a. realistischer Zielsetzungen, einschließlich einer Kaskadierung in Teilziele. Neben dem ausgeprägten explorativen Charakter vieler Umsetzungsprozesse führt diese Situation häufig auch zu einem Over-Engineering bei der Entwicklung, was sich in einem Umsetzungsstand von 2,7 in Bezug auf die **Komplexitätsbeherrschung** äußert. Die mangelnde Zielorientierung hängt auch mit dem Fehlen **strategischer Vorgaben** durch die Unternehmensführung zusammen, welche ebenfalls nur eine Ausprägung von 2,6 aufweisen. Demnach existieren bei vielen Unternehmen bereits Strategien für die digitale Transformation;

eine spezifische Auseinandersetzung mit ML und der Ableitung einer langfristigen Bedeutung der Technologie für das jeweilige Unternehmen sowie einer Vorgabe geeigneter strategischer Ziele und Maßnahmen hat bisher jedoch nur vereinzelt stattgefunden. Diese fehlende Auseinandersetzung bezieht sich auch auf spezifische **rechtliche und ethische Regeln** zum Einsatz von ML-Anwendungen für die Übernahme von Entscheidungen. Bestehende Vorgaben beschränken sich auf den Aspekt der Datennutzung, sodass auch hier nur ein Umsetzungsstand von 2,7 erreicht wird. Im Zusammenhang mit projektspezifischen und strategischen Zielsetzungen ist zudem eine mangelnde **Transparenz** für die Stakeholder zu beobachten (2,5). Diese führt zu einer Unkenntnis über spezifische Anwendungen und deren Bedeutung für das Unternehmen. In Verbindung mit dem allgemein fehlenden **Wissen** zu ML, was mit Abstand den geringsten Umsetzungsstand aufweist (1,9), entstehen Vorbehalte und Ängste bei bestimmten Organisationsmitgliedern. Viele Mitarbeiter nehmen ML demnach eher negativ wahr, da sie eine Degradierung gegenüber den Systemen oder einen Verlust ihrer Arbeit befürchten. Hieraus resultiert für die gegenwärtige **Akzeptanz** ein Umsetzungsstand von 2,6.

Bei einem Vergleich beider Bewertungsdimensionen zeigt sich, dass der Umsetzungsstand der Eigenschaften in keinem Fall der jeweiligen Bedeutung gerecht wird (siehe Abbildung 67). Die höchste Differenz mit jeweils 1,8 liegt für die interdisziplinäre Kooperation, die Transparenz sowie die Verfügbarkeit personeller und finanzieller Ressourcen vor.




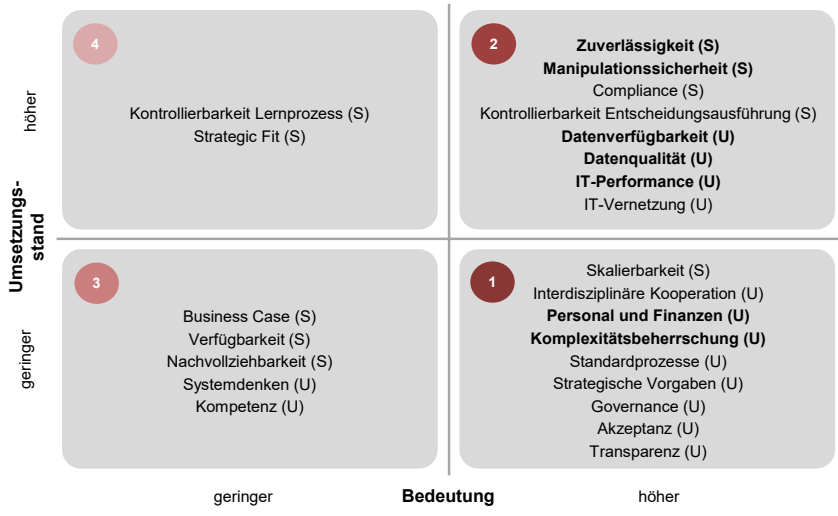
Abbildung 67: Umfeldeigenschaften – relative Bewertung⁶⁶⁵

⁶⁶⁵ Eigene Darstellung. Es ist die Abweichung zum jeweiligen Mittelwert dargestellt.

6.5.4 Priorisierung

Im Rahmen der vorliegenden Untersuchung wurde eine Vielzahl von Voraussetzungen identifiziert, die für einen erfolgreichen Einsatz von ML-Anwendungen im Logistikmanagement zu realisieren sind. Diese betreffen insgesamt ein sehr **breites Spektrum von unterschiedlichen Gestaltungsbereichen** und gehen dabei weit über „klassische“ Entwicklungstätigkeiten von IT-Projekten und Aktivitäten zur Datenbereitstellung hinaus. Vielmehr bedarf es zusätzlicher ablauf- und aufbauorganisatorischer sowie auch kultureller Veränderungen in den Unternehmen. Ferner müssen rechtliche, soziale und ethische Fragstellungen zum Einsatz von ML in Entscheidungsprozessen beantwortet und auf strategischer Ebene verankert werden.

Trotz ihrer hohen postulierten Bedeutung für den Erfolg des Technologieeinsatzes liegen die identifizierten Voraussetzungen bisher nur sehr eingeschränkt in den Unternehmen vor. Demnach erfüllen weder die bereits umgesetzten ML-Anwendungen noch die gegenwärtigen Umfeldbedingungen die formulierten Anforderungen. Neben den Non-Adoptern lässt sich diese Diskrepanz auch für die Adopter feststellen, welche insgesamt nur einen marginal höheren Umsetzungsstand aufweisen. Hieraus leitet sich für die Unternehmen in der Logistik ein **höher Handlungsbedarf** zur Verbesserung der benötigten Voraussetzungen ab, welcher durch geeignete Maßnahmen zu bewältigt ist. Entsprechend der damit einhergehenden Umsetzungscomplexität und des hohen erwarteten Aufwands ist hierfür jedoch eine voraussehende Priorisierung erforderlich. Diese kann auf Grundlage der empirischen Befragungsergebnisse abgeleitet werden. Durch eine Integration der gesamten Qualitäts- und Umfeldeigenschaften sowie deren Klassifikation in Bezug auf den Mittelwert der beiden Bewertungsdimensionen lässt sich demnach eine **Rangfolge der Anforderungen** gemäß ihrer Zuordnung zu vier Prioritätsbereichen aufstellen (siehe Abbildung 68). Diese Systematisierung reicht von Anforderungen mit einer vergleichsweise geringen Bedeutung und einem gleichzeitig vergleichsweise hohen Umsetzungsstand, was der geringsten Priorität „4“ entspricht, bis hin zu Anforderungen mit einer hohen Bedeutung und gleichzeitig einem geringen Umsetzungsstand, was als höchste Priorität „1“ betrachtet wird.



Legende: S = Systemeigenschaften U = Umfeldeigenschaften *höchste Bedeutung für Adopter*

Abbildung 68: Priorisierung der geforderten Qualitäts- und Umfeldeigenschaften⁶⁶⁶

Anhand der vorgenommenen Klassifikation ist festzustellen, dass mehrere sehr bedeutsame Anforderungen existieren, die bereits einen vergleichsweise hohen Umsetzungsstand aufweisen. Hierzu zählen die benötigten infrastrukturellen und datenseitigen Voraussetzungen sowie die Sicherheit, Kontrollierbarkeit, Compliance und Zuverlässigkeit der ML-Anwendungen. Demgegenüber stehen Eigenschaften mit einer sehr **stark ausgeprägten Diskrepanz** zwischen beiden Bewertungsdimensionen, welche nachfolgend aufgeführt sind und einen Schwerpunkt für die nachfolgenden Arbeiten aufweisen:

- langfristige Vorgabe von Zielen, Maßnahmen und Richtlinien für den Einsatz von ML-Anwendungen,
- Etablierung eines Prozesses zur systematischen Identifikation und Umsetzung von Anwendungen,
- Vorgabe klarer und realistischer Zielstellungen für Umsetzungsprozesse, die zur Reduzierung der damit verbundenen Komplexität beitragen,
- Realisierung skalierbarer Anwendungen,
- Bereitstellung von finanziellen und personellen Ressourcen für die Umsetzung,
- Möglichkeit zur Einbindung von Vertretern aus mehreren Unternehmensbereichen,
- Schaffung von Transparenz zum Einsatz von ML und
- Sicherstellung einer Akzeptanz bei allen Mitarbeitern.

⁶⁶⁶ Eigene Darstellung. Die vier ermittelten funktionalen Eigenschaften sind in dieser Übersicht nicht berücksichtigt, da sie eine übergreifende Relevanz aufweisen.

7 Gestaltungsansatz

Ausgehend vom dem zuvor formulierten Handlungsbedarf und unter Berücksichtigung der in der vorliegenden Arbeit erzielten Teilergebnisse werden in diesem Kapitel geeignete Maßnahmen für einen erfolgreichen Einsatz von ML im Logistikmanagement erarbeitet. Für die Bereitstellung eines durch die Praxis nutzbaren Unterstützungsinstrumentes werden die einzelnen Handlungsempfehlungen in Form eines Gestaltungsansatzes systematisiert und anschließend im Anwendungszusammenhang geprüft. Dies soll die fünfte sekundäre Forschungsfrage beantworten:

Welche Maßnahmen eignen sich für einen erfolgreichen Einsatz von ML-Anwendungen im Logistikmanagement und wie lassen sich diese in einen übergreifenden Gestaltungsansatz integrieren?

Einleitend wird das Forschungsdesign zur Entwicklung und Validierung des Gestaltungsansatzes beschrieben, was auch dessen zusammenfassende Darstellung umfasst (Kapitel 7.1). In den anschließenden sechs Unterkapiteln erfolgt eine Ausarbeitung der einzelnen Maßnahmen anhand einer einheitlichen Struktur, zu der auch eine initiale Zusammenfassung des jeweils zugrundeliegenden Handlungsbedarfes sowie eine abschließende Prüfung der Maßnahmen zählt (Kapitel 7.2 bis 7.7). Im letzten Unterkapitel werden die Erkenntnisse der Validierung für den gesamten Gestaltungsansatz zusammengefasst (Kapitel 7.8).

7.1 Forschungsdesign und Übersicht

In diesem Subkapitel erfolgt eine prägnante Darstellung des Vorgehens zur Entwicklung und Validierung des Gestaltungsansatzes, einschließlich der damit einhergehenden Zielsetzung sowie einer Zusammenfassung der enthaltenen Handlungsfelder (HF) und des verwendeten Anwendungsfalls für die Prüfung der Ergebnisse.

7.1.1 Entwicklung

Mit der Entwicklung der Maßnahmen und deren Systematisierung in Form des Gestaltungsansatzes wurde das Ziel einer Befähigung von Unternehmen zum erfolgreichen Einsatz von ML-Anwendungen im Logistikmanagement verfolgt. Für den diesbezüglichen Forschungsprozess wurden die im vorherigen Kapitel erhobenen Anforderungen entsprechend ihres kontextuellen Bezuges als zu realisierende Sollzustände herangezogen. Hierbei wurde eine **Fokussierung der Anforderungen** mit einer vergleichsweise hohen Bedeutung gemäß der Priorisierung in Kapitel 6.5.4 vorgenommen. Im Einklang mit dem übergreifend hohen bis sehr hohen Bedeutungsniveau führte diese Schwerpunktsetzung jedoch nicht zur Exklusion einzelner Anforderungen. Vielmehr sollten sowohl technologische als auch organisatorische und soziale Dimensionen, einschließlich deren Schnittstellen, integrativ betrachtet werden, wie es vom MTO-Konzept insbesondere für digitale Technologien gefordert wird (siehe Kapitel 2.1.3.3).

Die Grundlage für die Maßnahmenentwicklung bildeten die vorausgegangenen Erkenntnisse der vorliegenden Arbeit, welche zu diesem Zweck synthetisiert wurden (siehe Abbildung 69). Dies umfasste auf der einen Seite die technologiespezifischen **Eigenschaften von ML** aus Kapitel 2.4, anhand derer sich teils erhebliche Unterschiede zu anderen Entscheidungstechniken ableiten lassen. Auf der anderen Seite wurden die spezifischen **Rahmenbedingungen der betrachteten Domäne** in Form der Logistik bzw. speziell des Logistikmanagements herangezogen. Neben Informationen zur strategischen Bedeutung von ML und dessen Stand in der Praxis aus Kapitel 2.4 beinhaltete dies auch Erkenntnisse zum Umsetzungsstand von ML-spezifischen Voraussetzungen aus Kapitel 6. Gleichzeitig wurden die in Kapitel 4.4 identifizierten **Entwicklungen** zum Forschungsstand von ML und zur Logistik berücksichtigt. Als „Bezugsobjekt“ für den Forschungsprozess fungierte das realisierbare Anwendungsspektrum von ML aus Kapitel 5.2 mit den erwarteten Implikationen für die Ausführung von Entscheidungsprozessen aus Kapitel 5.4. Einen wichtigen Impuls für die Maßnahmenentwicklung stellten zudem die Erkenntnisse der **Fallstudienforschung** aus Kapitel 4.3 dar.



Abbildung 69: Synthese der Teilergebnisse der Arbeit für Maßnahmenentwicklung⁶⁶⁷

Die auf Grundlage dieser Synthese identifizierten Maßnahmen beziehen sich sowohl auf die Gestaltung von ML-Anwendungen als auch auf die Gestaltung des hierfür benötigten Umfelds in den Unternehmen. Entsprechend ihrer inhaltlichen Ausrichtung wurden sie zu insgesamt **sechs Handlungsfeldern** zusammengefasst, welche unterschiedliche Gestaltungsbereiche bzw. Managementdisziplinen repräsentieren und strukturgebend für den in Abbildung 70 dargestellten Gestaltungsansatz sind. Hierzu gehören die strategische Planung als übergeordneter Rahmen für den Einsatz von ML im betreffenden Unternehmen (HF 1), die Ablauforganisation (HF 2), die Aufbauorganisation (HF 3), die Arbeitsorganisation zwischen ML-Anwendungen und Entscheidungsträgern in Form der Mensch-Computer-Interaktion (HF 4), das Kompe-

⁶⁶⁷ Eigene Darstellung

tenzmanagement (HF 5) sowie das Datenmanagement als Fundament für die technische Realisierbarkeit von ML (HF 6). Ein Spezifikum stellen die ablauforganisatorischen Maßnahmen des HF 2 dar, welche sich auf einen zu etablierenden Standardprozess für die Auswahl und Umsetzung von ML-Anwendungen in den Unternehmen beziehen. Hierfür wurde ein **Vorgehensmodell** mit mehreren Phasen entwickelt und in den Gestaltungsansatz integriert.

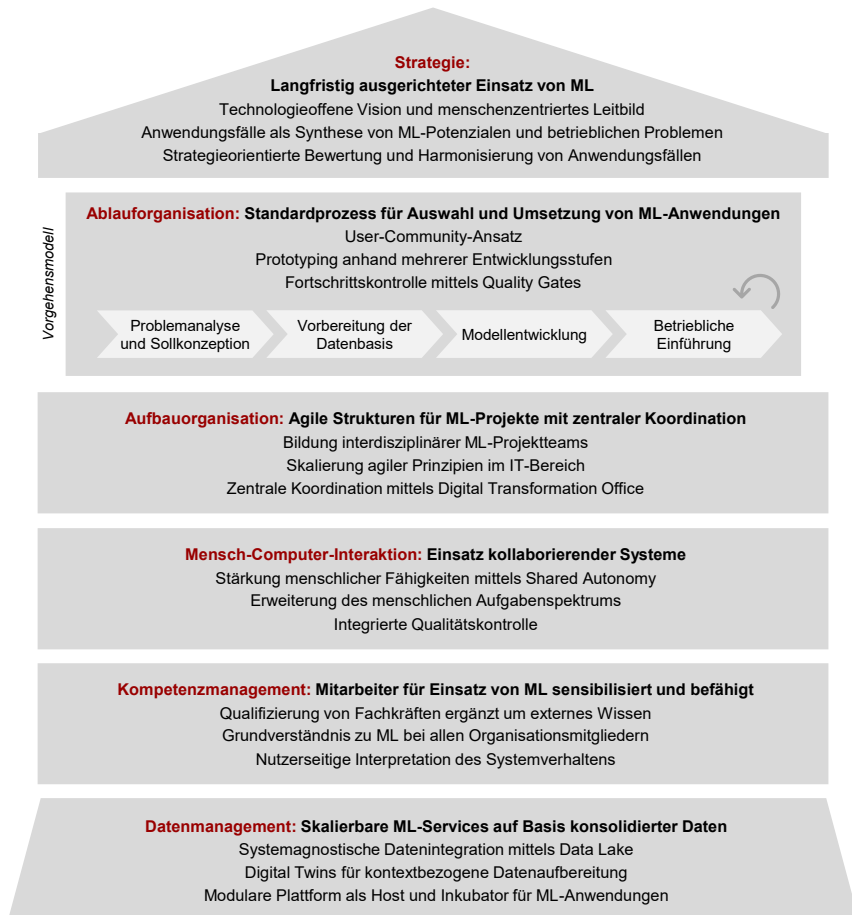


Abbildung 70: Gestaltungsansatz für den Einsatz von ML im Logistikmanagement⁶⁶⁸

Die Darstellung der HF in den einzelnen Unterkapiteln folgt einer einheitlichen Struktur. Vor ihrer detaillierten Beschreibung werden die Maßnahmen der jeweiligen HF zusammen mit der anzustrebenden Zielsetzung und dem zugrundeliegenden Handlungsbedarf vorgestellt. Letzteres resultiert aus einer Gegenüberstellung der spezifischen Eigenschaften von ML und der

⁶⁶⁸ Eigene Darstellung

Ausgangssituation in der Logistik, einschließlich relevanter Entwicklungen. Zur Unterstützung zentraler Arbeitsaktivitäten werden für die einzelnen Maßnahmen geeignete **Methoden und Werkzeuge** aufgezeigt, wobei es sich in mehreren Fällen auch um Teilergebnisse der vorliegenden Arbeit handelt, u. a. in Form der ML-Typologie, der Eignungsindikatoren mit den Wirkungsdimensionen sowie der Anforderungen von ML-Anwendungen. Zwischen den Maßnahmen bestehen – auch handlungsfeldübergreifend – starke **Zusammenhänge**, auf die entsprechend verwiesen wird. Am Ende jedes HF werden die Maßnahmen anhand eines praktischen Anwendungsfalls validiert.

7.1.2 Validierung

Das Erreichen der mit der Entwicklung des Gestaltungsansatzes intendierten Zielsetzung ist gemäß des gewählten Forschungsprozesses nach *Ulrich (1981)* zu überprüfen, wofür eine **empirische Erfolgsmessung** der Inhalte im korrespondierenden Anwendungskontext erforderlich ist (siehe Kapitel 1.3.2). Im Idealfall umfasst dies eine evaluierende Begleitung der Umsetzung des Gestaltungsansatzes in Unternehmen. Entsprechend des inhaltlichen Spektrums der entwickelten Ergebnisse sind dabei Aktivitäten von der strategischen Planung des Technologieeinsatzes bis zur betrieblichen Einführung von ML-Anwendungen zu prüfen. Aufgrund der Länge des damit einhergehenden Betrachtungszeitraums ist dieser Validierungsansatz jedoch für die vorliegende Untersuchung nicht realisierbar. Eine geeignete Alternative stellt dagegen die Prüfung der Ergebnisse anhand eines **bereits realisierten ML-Anwendungsfalls** dar, wodurch Erkenntnisse zu den damit verbundenen Aktivitäten genutzt werden können. In der vorliegenden Arbeit wird diesem zweiten Ansatz durch die Verwendung eines repräsentativen ML-Anwendungsfalls gefolgt, an dessen Umsetzung der Autor im Rahmen eines mehrjährigen Forschungsprojektes in Zusammenarbeit mit verschiedenen Unternehmen beteiligt war (siehe Kapitel 1.3.2). Im Gegensatz zu einer Erhebung der Informationen zu ML-seitigen Aktivitäten von Dritten, z. B. durch die Befragung von Unternehmen, kann durch die Nutzung dieses Anwendungsfalls und der damit verbundenen Einbindung des Autors das benötigte **Informationsspektrum für die Validierung** aller zentralen Inhalte des Gestaltungsansatzes sichergestellt werden.

Das Vorgehen des gewählten Validierungsansatzes setzt sich aus zwei Schritten zusammen, die mit ihren Prüfkriterien in Tabelle 19 zusammengefasst sind. Im ersten Schritt wird die praktische **Anwendbarkeit** des Gestaltungsansatzes für das Untersuchungsfeld in Bezug auf eine inhaltliche und strukturelle Logik überprüft, indem fallspezifische Ausprägungen zu wesentlichen Maßnahmen, einschließlich der Schritte des Vorgehensmodells und einzelner Methoden, ermittelt werden. Im Falle einer inhaltlichen Abdeckung durch bereits erfolgte Aktivitäten im Kontext des betrachteten Anwendungsfalls wird bei dieser „**Operationalisierung**“ auf bestehende Informationen zurückgegriffen.⁶⁶⁹ Für alle nicht abgedeckten Inhalte werden realistische

⁶⁶⁹ Die einbezogenen Informationen zum Anwendungsfall für die Validierung entstammen dem Abschlussbericht des Forschungsprojektes: Straube et al. (2020a).

Ausprägungen für den Anwendungsfall konzeptionell durch den Autor ermittelt. Im zweiten Schritt erfolgt eine qualitative Bewertung der **Zweckmäßigkeit** des Gestaltungsansatzes in Hinblick auf dessen Beitrag zum erfolgreichen Einsatz von ML-Anwendungen. Im Sinne ihrer Funktion als zu realisierende Sollzustände werden dazu die in Kapitel 6 ermittelten Anforderungen herangezogen, wobei geprüft wird, inwiefern die operationalisierten Maßnahmen zu einer Erfüllung der einzelnen Anforderungen beitragen. Durch eine Gesamtbetrachtung der abgedeckten Anforderungen mit ihren fallspezifischen Ausprägungen können anschließend Aussagen zum voraussichtlichen Nutzen des Gestaltungsansatzes im Sinne seiner **Erfolgswirkung** abgeleitet werden.

Kriterium	Fragestellung für Validierung	Validierungsschritt für Anwendungsfall
Anwendbarkeit	Ist der Gestaltungsansatz für den Einsatz von ML-Anwendungen anwendbar?	Ermittlung der Ausprägungen der Inhalte des Gestaltungsansatzes (Operationalisierung)
Zweckmäßigkeit (Nutzen)	Leistet der Gestaltungsansatz einen positiven Beitrag zum erfolgreichen Einsatz von ML-Anwendungen?	Ermittlung der Erfüllung der Anforderungen gemäß der Operationalisierung

Tabelle 19: Kriterien und Schritte der Validierung

Der Anwendungsfall für die Validierung bezieht sich auf eine ML-Anwendung zur Prognose von Prozess- bzw. Ankunftszeiten (ETA) für Seefrachtcontainer im maritimen Vorlauf, welche vordergründig in der **Transportplanung und -steuerung** für Exportaufträge zum Einsatz kommen soll. Die zugrundeliegende Prozesskette dieser Anwendung beginnt bei der Gestellung und Beladung eines Leercontainers beim industriellen Verladener und endet bei der Verladung des Containers auf einem Seeschiff im Hafen, weshalb in diesem Zusammenhang auch von einer **Door-to-Port-ETA** gesprochen wird. An die für den Anwendungsfall relevante Prozesskette schließt sich der Hauptlauf des Seeschiffs sowie ein landseitiger Nachlauf an, der mit der Auslieferung des Containers beim jeweiligen Kunden endet. Auf Basis der prognostizierten ETA soll die ML-Anwendung zusätzlich geeignete Aktionen für die Planung und Steuerung des jeweiligen Transportauftrages bereitstellen, was mittels eines wissensbasierten Systems realisiert wird. Zur Erhöhung der Repräsentativität wird als organisatorisches Umfeld für den betrachteten „**ETA-Anwendungsfall**“ ein fiktives Unternehmen angenommen, welches sich noch am Anfang des Adoptionsprozesses von ML befindet (siehe Kapitel 2.1.3.1). Demnach wurden in dem Unternehmen bisher weder entsprechende Systeme inner- und außerhalb der Logistik umgesetzt noch größere analytische oder konzeptionelle Aktivitäten zu ML betrieben.

7.2 Strategie: Langfristig ausgerichteter Einsatz von ML

Das Ziel der Maßnahmen dieses HF ist die Sicherstellung eines langfristig ausgerichteten Einsatzes von ML in Hinblick auf übergeordnete Unternehmensziele. Dies bezieht sich sowohl auf eine Maximierung des wirtschaftlichen Nutzens als auch auf einen ethisch achtsamen Umgang beim Einsatz der Technologie. Ausgehend von einer Auseinandersetzung mit den Fähigkeiten

und Auswirkungen von ML ist durch die Unternehmensführung eine Vision und ein Leitbild für den langfristigen Einsatz vorzugeben. Zum Erreichen dieser Zielsetzung sind auf Basis einer Betrachtung des Anwendungspotenzials von ML und der vorherrschenden Probleme in den Unternehmen geeignete Anwendungsfälle zu identifizieren. Diese sind in Hinblick auf ihren Beitrag zur Realisierung der Vision zur bewerten und mit anderen langfristigen Maßnahmen in Form einer Strategie-Roadmap zu harmonisieren und zu terminieren. Eine Zusammenfassung der Maßnahmen mit dem zugrundeliegenden Handlungsbedarf findet sich in Abbildung 71.



Abbildung 71: Handlungsfeld Strategie – Übersicht⁶⁷⁰

7.2.1 Technologieoffene Vision und menschenzentriertes Leitbild

Für den Einsatz von ML-Anwendungen zur Unterstützung oder Ausführung von logistischen Entscheidungsprozessen ist eine Vision und ein übergeordnetes Werteverständnis durch die Unternehmensführung zu entwickeln. Neben der wirtschaftlichen Bedeutung in Form einer Steigerung der Effizienz und Produktivität umfasst dies auch soziale Implikationen, welche insbesondere in Verbindung mit Veränderungen der menschlichen Aufgaben und einer potenziellen Reduktion von Arbeitsplätzen stehen. Hierzu bedarf es einer vorausgehenden **Auseinandersetzung mit den positiven sowie negativen Auswirkungen** des Einsatzes von ML,

⁶⁷⁰ Eigene Darstellung

wofür auf die Erkenntnisse der vorliegenden Arbeit aus Kapitel 5.4.1 zu den Wirkungsdimensionen und den daraus resultierenden Potenzialen bzw. Risiken zurückgegriffen werden kann.

Die Vision ist dabei nicht in Hinblick auf die Realisierung von ML zu formulieren, sondern hinsichtlich **langfristig angestrebter Veränderungen** der Unternehmen – welche sich neben den Fähigkeiten von ML auch auf andere Technologien beziehen können. Im Kontext der Logistik bietet sich hierzu eine Orientierung an den in Kapitel 1.1 dargestellten Stufen zur Realisierung einer „intelligenten Logistik“ an, welche perspektivisch eine autonome Selbststeuerung von Wertschöpfungssystemen vorsehen. Zusätzlich sind ein Realisierungshorizont sowie ggf. quantitative Zielgrößen und bestimmte adressierte Teilbereiche festzulegen. Durch die **technologieoffene Ausrichtung** der Vision wird die Möglichkeit eines Rückgriffs auf unterschiedliche technische Ansätze bei der Lösung damit verbundener Probleme gewahrt. Dementsprechend sind auch im Falle bestehender Visionen in den Unternehmen, z. B. im Kontext der digitalen Transformation, Industrie 4.0 oder Smart Factory, keine „parallelen“ ML-spezifischen Visionen zu entwickeln, sondern nur entsprechende Anpassungen bzw. Ergänzungen in Bezug auf die Fähigkeiten von ML vorzunehmen. Die zu entwickelnde Vision fungiert als Treiber für eine kontinuierliche Auseinandersetzung der Organisationsmitglieder mit den durch den Einsatz von ML angestrebten Auswirkungen und stellt dabei gleichzeitig ein zielorientiertes Vorgehen, z. B. bei der Festlegung von Anwendungsfällen, durch einen regelmäßigen Abgleich mit der Vision sicher.

Das zusätzlich zu entwickelnde Werteverständnis enthält normative Vorgaben zu einem ethisch achtsamen Umgang mit ML. Ein geeignetes Leitbild stellt die Realisierung eines auf den Menschen ausgerichteten Einsatzes von ML dar, welches auch als „**Human-centric AI**“ bezeichnet wird⁶⁷¹. Hierbei werden die Organisationsmitglieder sowohl bei der Auswahl und Gestaltung der Anwendungen als auch bei der Gestaltung der Arbeitsabläufe fokussiert, was – neben der Realisierung der wirtschaftlichen Potenziale – langfristig auch zu einer **Verbesserung der Arbeitsbedingungen** für die Menschen führen soll. Die Orientierung am Menschen bezieht sich dabei ebenfalls auf die Zuverlässigkeit und Fehleranfälligkeit der ML-Anwendungen, wonach keine höheren Anforderungen an systemseitige Ergebnisse im Vergleich zu den menschlichen Fähigkeiten gestellt werden.

Die Vision und das Leitbild sind zusammen mit Informationen zur Bedeutung von ML für die zukünftige Wettbewerbsfähigkeit der Unternehmen sowie zu Veränderungen der Arbeitsorganisation über verschiedene Kanäle in den Unternehmen **zu kommunizieren**, z. B. durch Betriebsversammlungen, Newsletter und Mitarbeiterzeitschriften.

⁶⁷¹ Vgl. Europäische Kommission (2019), S. 10

7.2.2 Anwendungsfälle als Synthese von ML-Potenzialen und betrieblichen Problemen

Für den Einsatz von ML in logistischen Entscheidungsprozessen sind geeignete Anwendungsfälle in den Unternehmen zu identifizieren, welche zur Realisierung der jeweils festgelegten Vision beitragen. Auch bei diesen Aktivitäten ist grundsätzlich ein technologieoffenes Vorgehen zu wählen, wobei – entsprechend der hohen strategischen Bedeutung – eine dedizierte Betrachtung von ML im Rahmen einer initialen Analyse empfohlen wird. Bei diesem systematischen Vorgehen ist einerseits das Anwendungspotenzial von ML und andererseits der prozessuale „Bedarf“ in den Unternehmen zu erschließen sowie anschließend gegenüberzustellen und in Bezug auf eine Übereinstimmung im Sinne eines „Matchmakings“ zu überprüfen. Hierzu kann auf die Erkenntnisse aus Kapitel 5 zum Anwendungsspektrum und zu den Eignungsindikatoren von ML zurückgegriffen werden.




Abbildung 72: Gegenüberstellung von Technologiepotenzial und betrieblichen Problemen⁶⁷²

In Hinblick auf das Anwendungspotenzial ist ein Verständnis zum theoretisch **realisierbaren Anwendungsspektrum** von ML für die Unternehmen zu entwickeln. Dazu sind bestehende Anwendungen aus Forschung und Praxis zu analysieren sowie Informationen zu Eignungskriterien und Fähigkeiten der Technologie einzuholen, welche der Konzeption eigener Ideen für Anwendungen dienen. In einem nachfolgenden Schritt ist der Bedarf des Unternehmens in Form **aktueller Defizite und Verbesserungsmöglichkeiten** bei der Ausführung von Entscheidungsprozessen zu analysieren, wobei sowohl bisher manuell ablaufende Prozesse als auch bereits durch andere Entscheidungstechniken unterstützte Aufgaben zu berücksichtigen sind. Zur Einholung der entsprechenden Informationen sind geeignete Vertreter aus den logistischen Fachbereichen zu befragen, welche neben den Problemen auch entsprechende Hintergründe darstellen können. Ergänzend sind Qualitätsberichte, z. B. aus Auditierungen, und bestehende Ideen aus dem betrieblichen Vorschlagswesen zu berücksichtigen. Anschließend sind die Erkenntnisse zu den Potenzialen und Bedarfen zusammenzuführen. Im Rahmen dieses **Matchmakings** ist zu prüfen, inwiefern die identifizierten Probleme durch ML gelöst werden können. Neben einer Abdeckung ähnlicher Problemstellungen durch bestehende Anwendungen stellen dabei die benötigten technischen Fähigkeiten, z. B. die Prognose zukünftiger Zustände, sowie die vorliegenden Problemmerkmale, z. B. eine hohe Anzahl von dynamischen

⁶⁷² Eigene Darstellung

Einflussvariablen, geeignete Prüfkriterien dar. Während die bei diesem Vorgehen identifizierten Probleme potenzielle Anwendungsfälle für ML darstellen, sind die restlichen Probleme auf eine etwaige Eignung für den Einsatz anderer Entscheidungstechniken zu überprüfen.

Zusätzlich zu diesem Matchmaking sind anhand des „**verborgenen Bedarfes**“ der Unternehmen weitere Anwendungsfälle für ML zu ermitteln. Hierbei handelt es sich um betriebliche Probleme, die aufgrund einer vermuteten Unlösbarkeit oder einer fehlenden Wahrnehmung bisher nicht durch die Fachbereichsvertreter artikuliert wurden. Letzteres steht oft im Zusammenhang mit einem Gewöhnungseffekt der Mitarbeiter, welcher nur durch externe Impulse in Form des Aufzeigens alternativer Lösungsmöglichkeiten überwunden werden kann. Vor diesem Hintergrund sind die Fachbereichsvertreter mit den Fähigkeiten von ML und über die bisher benannten Anwendungsfälle hinausgehenden Anwendungen zu konfrontieren. In diesem Kontext kann auch eine systematische Überprüfung aller Entscheidungsprozesse nach einer potenziellen Eignung für ML vorgenommen werden.

7.2.3 Strategieorientierte Bewertung und Harmonisierung von Anwendungsfällen

Die potenziell geeigneten Anwendungsfälle von ML sind einer zusätzlichen Spezifikation, Bewertung, Strukturierung und groben Terminierung zu unterziehen. Hierbei ist eine Verbindung mit anderen langfristigen Maßnahmen herzustellen, sodass eine **strategische Planung** mit verschiedenen Entwicklungspfaden – in der ML als Schlüsseltechnologie berücksichtigt ist – zur Realisierung der angestrebten Vision resultiert. Ausgehend von dieser übergreifenden Strategie kann anschließend eine Filterung von Maßnahmen für bestimmte Teilziele oder Unternehmensbereiche vorgenommen und eine Gestaltung des für ML benötigten Umfeldes initiiert werden, einschließlich einer Finanzierungs- und Personalplanung. Auch bei diesen Aktivitäten ist auf etwaige bereits bestehende Planungen aufzusetzen, z. B. in Form von Digitalisierungsstrategien.

Die Spezifikation der ML-Anwendungsfälle bezieht sich insbesondere auf die adressierte Problemstellung, die angestrebte technische Lösung und etwaige besondere Anforderungen, z. B. in Bezug auf die Daten oder die IT-Infrastruktur, um auch Aussagen zur Realisierbarkeit treffen zu können. Anhand dieser Informationen sind die Anwendungsfälle hinsichtlich ihrer Übereinstimmung und ihres **Wirkungsbeitrages zur Realisierung der Vision** zu bewerten sowie dementsprechend zu priorisieren und ggf. zu selektieren. Anschließend sind weitere langfristige Maßnahmen zur Realisierung der festgelegten Vision im Unternehmen zu betrachten, wobei es sich sowohl um die Umsetzung anderer Technologien als auch um Maßnahmen zu weiteren Gestaltungsbereichen handeln kann, z. B. in Bezug auf die Aufbau- und Ablauforganisation. Zwischen den einzelnen Maßnahmen, einschließlich der identifizierten ML-Anwendungsfälle, sind logische Abhängigkeiten, Redundanzen und Widersprüche aufzudecken und zu bewerten. Auf dieser Grundlage sind grobe Realisierungszeiträume für die einzelnen Maßnahmen sowie logische **Entwicklungspfade** festzulegen, bei denen es sich um Teilziele der

übergeordneten Zielstellung handelt. Zur Visualisierung der Planungsergebnisse ist eine **Roadmap** umzusetzen, welche eine prägnante Übersicht der einzelnen Maßnahmen und deren Verbindung im Zeitverlauf zum Erreichen der Vision ermöglicht. Die resultierende Roadmap ist ebenfalls in der Organisation zu kommunizieren, sodass das Bewusstsein für die notwendigen Tätigkeiten zum Erreichen der langfristigen Zielsetzung erhöht wird.

7.2.4 Validierung

Vor der Umsetzung einzelner ML-Anwendungen setzt sich die Führung des Unternehmens im ETA-Anwendungsfall mit den Potenzialen und Risiken von ML auseinander und bewertet die strategische Bedeutung der Technologie für die eigene Branche und das Unternehmen. Zusammen mit korrespondierenden Erkenntnissen zu anderen Technologien wird anschließend eine **technologieunspezifische Vision** für das Unternehmen formuliert, welche sich auf einen bestimmten logistischen Teilbereich bezieht: *„Realisierung einer autonomen Transportplanung und -steuerung für die Distributionslogistik bis zum Jahre 2030“*. In Hinblick auf die angestrebte Übernahme von vielen vormals manuellen Aufgaben durch den Einsatz von Technologien wird zudem ein übergreifendes **Leitbild** für deren achtsamen Einsatz im Unternehmen formuliert, welches sich u. a. gegen einen Abbau von Arbeitsplätzen ausspricht.

Für das Erreichen dieser Vision werden notwendige Aktivitäten identifiziert, was neben Prozessanpassungen auch die Einführung mehrerer Technologien beinhaltet. Hierzu ermittelt die Unternehmensführung anhand von Analysen zum Forschungsstand und von Wettbewerbsvergleichen das Anwendungspotenzial der einzelnen Technologien. Auf dieser Grundlage wird erkannt, dass die Realisierung einer autonomen Planung und Steuerung von Transporten die Entwicklung von zuverlässigen ETA-Prognosen erfordert, damit die entsprechenden IT-Systeme vorausschauend eine optimale Disposition von Aufträgen vornehmen können. Außerdem wird festgestellt, dass für die ML-basierte Realisierung von ETA-Prognosen bereits Lösungen für andere Transporte existieren, wie für die Seeschifffahrt und den Straßenverkehr. Unter Berücksichtigung der gewonnenen Informationen werden die Vertreter der Transportplanung und des Vertriebes lösungsoffenen nach aktuellen Problemen bei ihren Tätigkeiten befragt. Hierbei wird erkannt, dass die derzeitige Transportplanung und -steuerung mit hohen manuellen Aufwänden einhergeht und sehr fehlerbehaftet ist, was einerseits zu hohen Verspätungen der Transporte sowie andererseits zur Einplanung hoher Kapazitätspuffer und der Durchführung vieler Sondertransporte führt. Das resultiert wiederum in hohen Kosten sowie einer bevorzugten Wahl vieler Kunden von anderen Transportmodi zur Beförderung ihrer Güter. Durch eine Realisierung verlässlicher Prognosen ist dieses Problem aus Sicht der Fachbereiche voraussichtlich abstellbar. Der Anwendungsfall zur Realisierung einer ETA-Prognose entspricht demnach einem **Matchmaking** von einem bedeutenden Defizit des Unternehmens mit einem Anwendungspotenzial von ML – wobei die Realisierung einer entsprechenden Anwendung gleichzeitig im Einklang mit der formulierten Vision steht.

Der ETA-Anwendungsfall wird anschließend mit anderen geplanten Anwendungen und weiteren langfristigen Maßnahmen harmonisiert. Hierzu gehört z. B. die Ausstattung von Güterwagen mit Sensorik, wodurch nützliche Daten für die ETA-Anwendung bereitgestellt werden können. Die resultierende Planung wird mittels einer **Strategie-Roadmap** visualisiert, welche die einzelnen Maßnahmen inhaltlich und zeitlich in einen Bezug stellt. Ausgehend von der heutigen Situation im ETA-Anwendungsfall ergibt sich der in Abbildung 73 vereinfacht dargestellte Entwicklungspfad zur Realisierung der angestrebten autonomen Transportplanung und -steuerung. Die einzelnen Entwicklungsstufen stellen dabei systemseitige Zwischenstände dar, die jeweils über einzelne oder mehrere Projekte umgesetzt werden. Die ermittelte Roadmap wird anschließend gemeinsam mit der Vision in der Organisation kommuniziert.




Abbildung 73: Vision und Strategie-Roadmap im ETA-Anwendungsfall⁶⁷³

Nach Prüfung dieses HF anhand des ETA-Anwendungsfalls lässt sich eine Operationalisierung aller wesentlichen Aktivitäten sowie eine Erfüllung von fünf Anforderungen feststellen (siehe Tabelle 20).

⁶⁷³ Eine Darstellung in Anlehnung an Straube et al. (2020a), S. 117

Anforderung	Erfüllung im Anwendungsfall durch Maßnahmen des HF
Strategische Vorgaben	Es wird eine technologieoffene Vision erstellt, in der die Potenziale und Risiken von ML berücksichtigt sind. Auf dieser Grundlage erfolgt die Festlegung langfristiger Maßnahmen zum Einsatz von ML.
Governance	Das Leitbild und ein darauf basierendes Regelwerk führen zu einer Berücksichtigung von ethischen und rechtlichen Richtlinien beim Einsatz von ML im Unternehmen.
Standardprozesse	Im Rahmen eines systematischen Matchmakings der Anwendungspotenziale von ML mit bestehenden Problemen im Unternehmen werden unter Berücksichtigung der langfristigen Unternehmensziele geeignete Anwendungsfälle ausgewählt.
Transparenz	Durch die Verdichtung der langfristigen Ziele und Maßnahmen in Form einer Vision und einer Strategie-Roadmap, welche beide im Unternehmen kommuniziert werden, erhöht sich das Verständnis zum Einsatz von ML bei allen Organisationsmitgliedern.
Personal und Finanzen	Der Strategieplan, welcher die angestrebten ML-Aktivitäten des Unternehmens beinhaltet und in Abstimmung mit der Unternehmensführung festgelegt wird, stellt die Finanzierung der einzelnen ML-Projekte sicher.

Tabelle 20: Handlungsfeld Strategie – Erfüllung der Anforderungen

7.3 Ablauforganisation: Standardprozess zur Auswahl und Umsetzung von ML-Anwendungen

Das Ziel des in diesem HF beschriebenen Vorgehensmodells ist die Sicherstellung einer systematischen Auswahl und Umsetzung von geeigneten ML-Anwendungen, wofür dieses als **Standardprozess** in den Unternehmen zu etablieren ist. Im Kontext einer durchgehenden Betrachtung der angestrebten ML-Anwendung sieht das entwickelte Vorgehen die anfängliche Implementierung eines vereinfachten Systems vor, welches über mehrere Entwicklungsstufen in den jeweiligen Zielzustand überführt wird. Diese bewusste Reduzierung der Systemkomplexität im Sinne eines **Prototyping** schafft die benötigte Entwicklungsumgebung für eine experimentelle Erprobung verschiedener Lösungsansätze und ermöglicht dabei vergleichsweise schnelle Erkenntnisse zur grundsätzlichen Realisierbarkeit, zum bestmöglichen Ansatz sowie zu erzielbaren Potenzialen. Um bei diesen Aktivitäten eine konsequente Ausrichtung auf die Lösung eines festgelegten Problems der Unternehmen sicherzustellen, beinhaltet der Prozess mehrere Meilensteine mit definierten Soll-Zuständen in Form von **Quality Gates**. Die damit verbundene Fortschrittskontrolle führt zu einer frühzeitigen Detektion von ungeeigneten Anwendungsfällen und ermöglicht gleichzeitig ein „systematisches Experimentieren“ im Rahmen der Entwicklung. Um auch über eine initiale Analyse der Anwendungsfälle hinaus einen Zugang zu den benötigten daten- und prozessbezogenen Informationen zu erhalten, sieht das Vorgehen zudem eine kontinuierliche Einbindung von geeigneten Wissensträgern vor, wozu im besonderen Maße Repräsentanten der späteren Nutzergemeinschaft gehören. Durch diesen **User-Community-Ansatz** wird gleichzeitig eine Berücksichtigung der nutzerseitigen Anforderungen bei der Systemgestaltung sichergestellt. Eine Zusammenfassung der mit dem Vorgehensmodell verbundenen Maßnahmen und des zugrundeliegenden Handlungsbedarfes findet sich in Abbildung 74. Insgesamt führen diese Maßnahmen zu einer Operationalisierung

von zentralen Prinzipien der **agilen Softwareentwicklung** in Form der frühzeitigen Bereitstellung von IT-Systemen, der Orientierung an den Kundenbedürfnissen und der intensiven Zusammenarbeit mit den Vertretern der adressierten Geschäftsprozesse⁶⁷⁴.

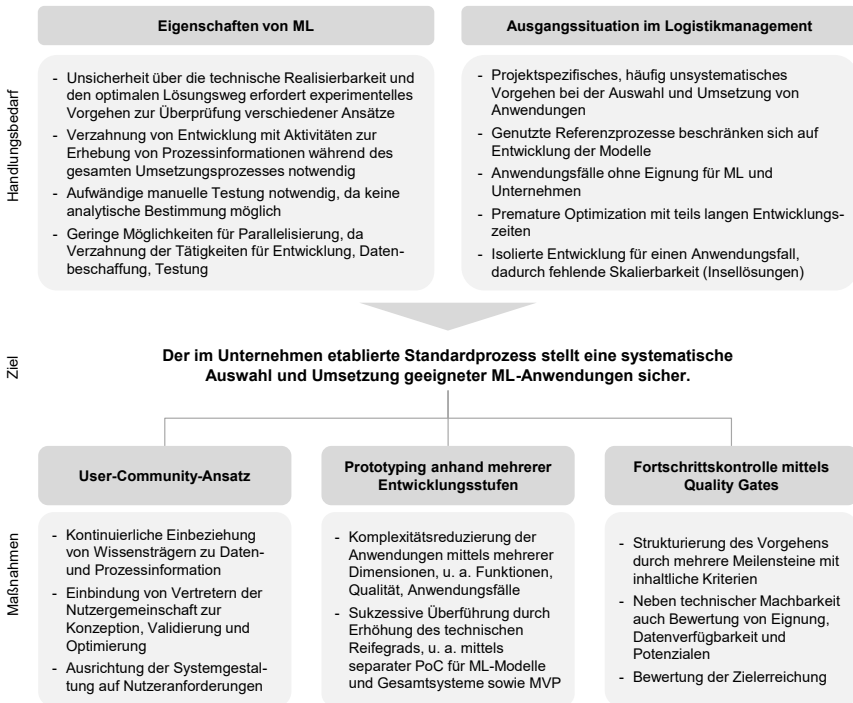


Abbildung 74: Handlungsfeld Ablauforganisation – Übersicht⁶⁷⁵

7.3.1 Struktur des Vorgehensmodells

Das Vorgehensmodell sieht **vier Phasen** mit jeweils mehreren Arbeitsschritten vor, wobei insbesondere die Aktivitäten der zweiten bis zur vierten Phasen im Falle von daten- und entwicklungsseitigen Anpassungen **iterativ zu durchlaufen** sind. In der ersten Phase bedarf es einer detaillierten Analyse des jeweiligen Anwendungsfalls, einschließlich der voraussichtlichen Datenverfügbarkeit, mit der Entwicklung eines Lösungskonzeptes, um darauf basierend Aussagen über dessen Eignung für den Einsatz von ML sowie um realistische Zielsetzungen für die Umsetzung der Anwendung ableiten zu können. Die zweite Phase umfasst Aktivitäten zur Bereitstellung der benötigten Daten, was deren Identifikation, Beschaffung, Aufbereitung und Analyse beinhaltet. Auf Grundlage dieser Datenbasis sind in der dritten Phase die ML-Modelle entsprechend einer festzulegenden Architektur zu implementieren. Die Operationalisierung

⁶⁷⁴ Vgl. Beck et al. (2001)

⁶⁷⁵ Eigene Darstellung

dieser Modelle ist in der vierten Phase vorzunehmen, was deren Integration in ein Gesamtsystem sowie eine Bereitstellung in der produktiven Zielumgebung mit anschließender Skalierung umfasst.

Die dargestellten Aktivitäten implizieren eine anfängliche Realisierung eines vereinfachten Systems, welches im Sinne eines Prototyping-Ansatzes sukzessive in die angestrebte ML-Anwendung überführt wird. Dazu sind mehrere **Entwicklungsstufen** mit unterschiedlichen technischen Reifegraden zu passieren, deren Ausprägungen sich an der Systematik der Technology Readiness Level (TRL) aus der Norm *ISO 16290:2013* orientieren. Die erste Stufe sieht die Umsetzung eines **Proof-of-Concept (PoC) für die ML-Modelle** vor, welches eine technische Machbarkeitsprüfung von kritischen Komponenten und darauf basierenden Funktionen ermöglicht. Die Entwicklungs- und Testaktivitäten finden dabei abseits der produktiven Systemumgebung statt (sog. Sandbox-Entwicklung und Offline-Testung) und können durch geringere Anforderungen an die systemseitigen Eigenschaften sowie durch eine Beschränkung auf ausgewählte Pilotanwendungsfälle bewusst in ihrer Komplexität reduziert werden. In der nachfolgenden Stufe sind die realisierten ML-Modelle mit anderen technischen Komponenten in ein Gesamtsystem in Form der angestrebten ML-Anwendung zu integrieren. Diese Aktivitäten erfolgen weiterhin abseits der Produktivumgebung und münden in einem **PoC für die ML-Anwendung**, anhand dessen eine technische Bewertung des übergeordneten Funktionsprinzips vorzunehmen ist. Anschließend ist das Gesamtsystem mit den wesentlichsten Funktionen in die Zielumgebung für ausgewählte Pilotanwendungsfälle zu überführen. Dieser sog. **Minimum Viable Prototype (MVP)** ermöglicht unter Realbedingungen eine frühzeitige Bewertung der technischen Machbarkeit und der angestrebten Potenziale (sog. Online-Testung). Anschließend ist dieses prototypische System durch die Integration der restlichen Funktionen und die Übertragung auf die weiteren festgelegten Anwendungsfälle in den jeweiligen Zielzustand zu überführen. Insgesamt sieht das Vorgehen damit eine Komplexitätsreduzierung nach mehreren Dimensionen entlang der einzelnen Entwicklungsstufen vor, welche in Tabelle 21 aufgeführt sind.

Dimension zur Komplexitätsreduzierung	Beschreibung
Funktionsumfang	Beschränkung auf „kritische“ Funktionen der Anwendung durch Realisierung der ML-Modelle und damit verbundener Komponenten
Einsatzbereich	Einsatz für ausgewählte Bereiche (Pilotanwendungsfälle), wodurch nur deren prozessuale Anforderungen und Daten zu berücksichtigen sind
Leistungs- und Qualitätseigenschaften	Reduzierte technische Anforderungen an Anwendung, z. B. geringere Zuverlässigkeit und Interpretierbarkeit
Systemumgebung	Kein Datenaustausch mit anderen Systemen, insbesondere für Output („Sandbox“); Entwicklung auf Basis historischer Input-Daten

Tabelle 21: Komplexitätsreduzierung der ML-Anwendungen beim Prototyping

Die einzelnen Entwicklungsstufen bilden eine wichtige Grundlage für die Strukturierung des Vorgehens in mehrere Quality Gates, deren Erreichen an bestimmte Kriterien geknüpft ist. Im

Falle einer Nichterfüllung dieser Kriterien ist eine Justierung oder gar ein Abbruch des ML-Projektes zu bewerten. Anders als beim TRL-Konzept beschränken sich die vorgesehenen Meilensteine jedoch nicht nur auf die Prüfung der technischen Machbarkeit, sondern berücksichtigen u. a. auch die Eignung des jeweiligen Anwendungsfalls für die Umsetzung mittels ML, die datenseitigen Voraussetzungen und die realisierten betriebswirtschaftlichen Potenziale. Insgesamt sind im Vorgehensmodell **neun Quality Gates** vorgesehen, welche mit ihren Zielsetzungen in Tabelle 22 dargestellt und projektspezifisch zu detaillieren sind.

Quality Gate	Zielformulierung	Aktivität der Fortschrittskontrolle
M1	Problem ist für ML geeignet	Eignungsprüfung
M2	Daten sind voraussichtlich gemäß Minimalanforderungen bereitstellbar	Daten-Pre-Check
M3	ML-Anwendung ist für Unternehmen geeignet und gegenüber anderen Alternativen vorzugswürdig	Auswahlentscheidung
M4	Daten liegen gemäß Minimalanforderungen vor	Prüfung der Datenbasis
M5	Technische Machbarkeit der ML-Modelle (PoC)	Test der ML-Modelle unter Offline-Bedingungen
M6	Technische Machbarkeit der ML-Anwendung (PoC)	Test der ML-Anwendung unter Offline-Bedingungen
M7	Technische Funktionsfähigkeit der ML-Anwendung (MVP)	Test der ML-Anwendung unter Online-Bedingungen
M8	ML-Anwendung erzielt festgelegten Nutzen (MVP)	Prüfung der Auswirkungen der ML-Anwendung
M9	ML-Anwendung ist vollständig einsatzfähig	Test der skalierten ML-Anwendung

Tabelle 22: Quality Gates des Vorgehensmodells

Die zum Erreichen der Quality Gates notwendigen Aktivitäten werden in den nachfolgenden Abschnitten im Rahmen der einzelnen Phasen des Vorgehensmodells beschrieben. Dies umfasst auch eine Darstellung von geeigneten Methoden, Werkzeugen und Dokumenten zur Unterstützung zentraler Schritte. Vorab findet sich in der Abbildung 75 eine Gesamtübersicht des Vorgehens mit den entsprechenden Unterstützungsinstrumenten. Entgegen der gewählten Darstellung können einzelne Schritte auch in einer anderen Sequenz oder parallel bzw. integriert durchgeführt werden. Im Sinne eines idealtypischen Szenarios wurde dem Vorgehen eine **parallel stattfindende Entwicklung der restlichen Komponenten** abseits der ML-Modelle zugrunde gelegt, deren Schritte aus Komplexitätsgründen nicht näher ausgeführt werden. Selbiges gilt für spezifische Aktivitäten zur Umsetzung von Anwendungen unter Verwendungen der Lerntypen des RL und EvL. Vielmehr beziehen sich die Aussagen v. a. auf die bisher in der Wissenschaft und Praxis dominierenden Typen des **SL und USL** sowie deren assoziierte „Subtypen“ des DL, SSL und EL (siehe Kapitel 2.4.3.2).

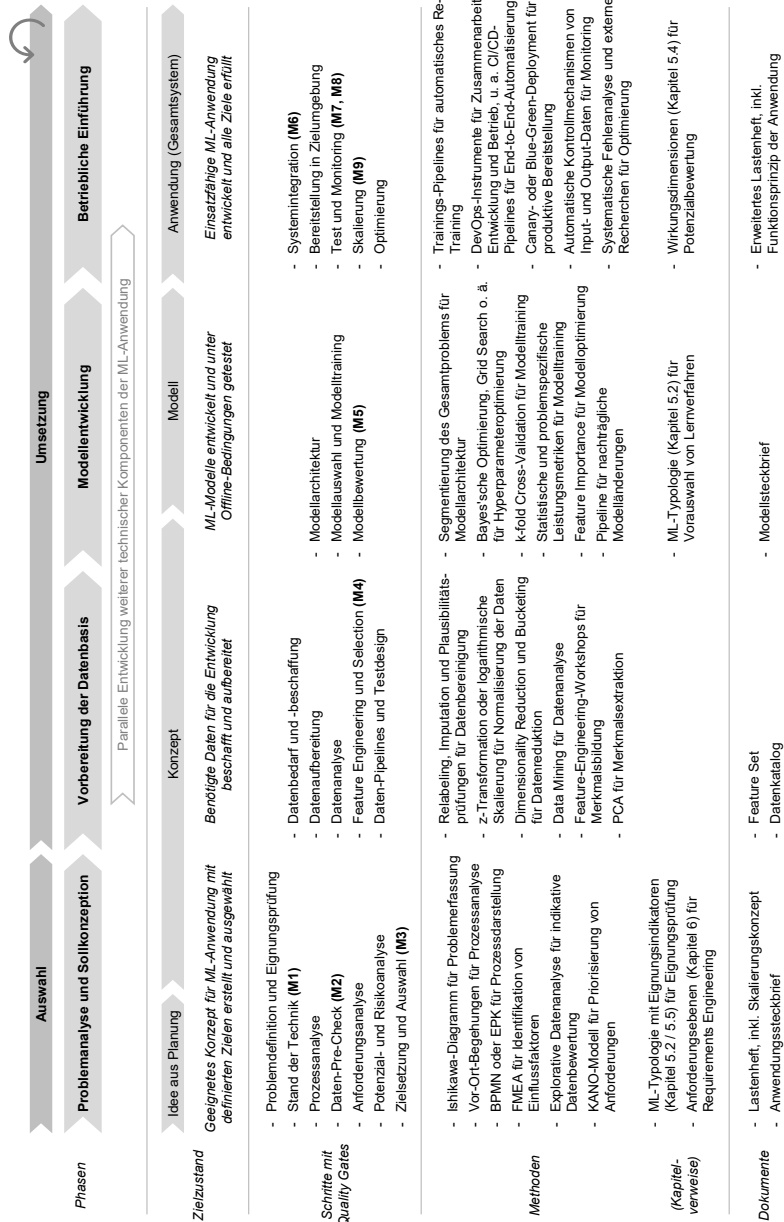


Abbildung 75: Vorgehensmodell für die Auswahl und Umsetzung von ML-Anwendungen⁶⁷⁶

⁶⁷⁶ Eigene Darstellung

7.3.2 Problemanalyse und Sollkonzeption

Vor der Entwicklung bedarf es einer analytischen Auseinandersetzung mit dem jeweiligen Anwendungsfall und der Ableitung eines angestrebten Lösungskonzeptes mit spezifischen technischen und betrieblichen Zielsetzungen für die angestrebte ML-Anwendung. Dies ermöglicht eine frühzeitige und fundierte **Bewertung der Eignung** des Anwendungsfall für den Einsatz von ML sowie für die Umsetzung im jeweiligen Unternehmen. Dazu sind in dieser vorausgehenden Analyse- und Konzeptionsphase verschiedene Aktivitäten auszuführen, die in Abbildung 76 zusammenfassend dargestellt sind.

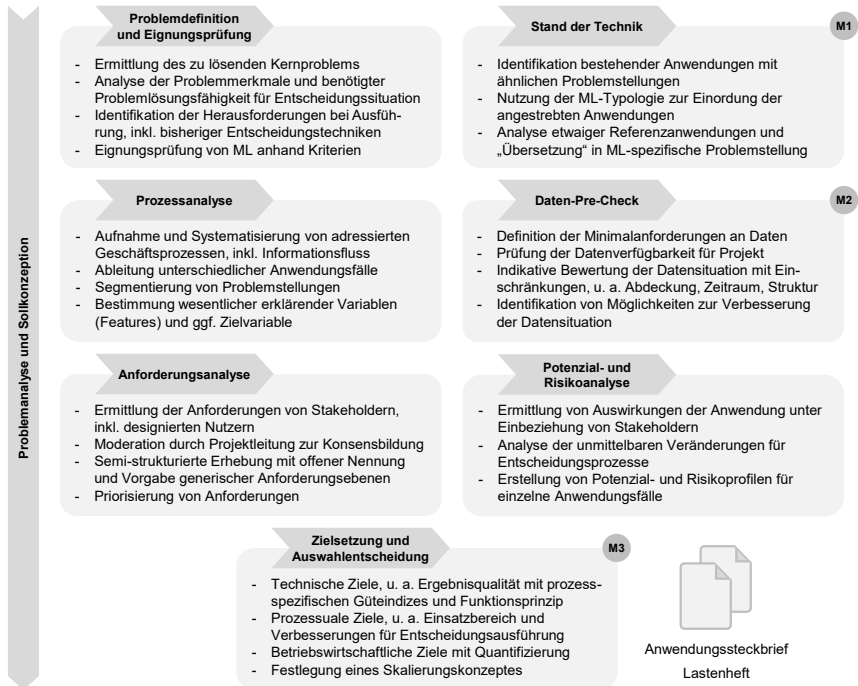


Abbildung 76: Problemanalyse und Zielformulierung – Vorgehen⁶⁷⁷

Zu Beginn dieser Phase sind das zu unterstützende Entscheidungsproblem und damit verbundene Herausforderungen bei der bisherigen Ausführung zu identifizieren. Anschließend ist eine Prüfung etwaiger Vorarbeiten in Wissenschaft und Praxis vorzunehmen, was neben einer Partizipation an bestehendem Wissen auch der „Übersetzung“ des Anwendungsfalls in eine ML-spezifische Problemstellung dient. Die gewonnenen Informationen beider Schritte sind für eine Eignungsbewertung von ML für die jeweilige Problemstellung zu nutzen (M1). Im An-

⁶⁷⁷ Eigene Darstellung

schluss sind die betroffenen Geschäftsprozesse zu analysieren, um Informationen zu verschiedenen Ausprägungen der Anwendungsfälle, zu Teilproblemen und beteiligten Stakeholder sowie zu Zielvariablen und potenziellen Einflussfaktoren zu gewinnen. Diese Informationen stellen die Grundlage für eine nachfolgende Prüfung der datenseitigen Voraussetzungen für das jeweilige ML-Projekt dar, was in einer technischen Machbarkeitsbewertung mündet (M2). Anschließend bedarf es einer Ermittlung der Anforderungen an die angestrebte Anwendung aus Sicht der Stakeholder sowie einer Erhebung der intendierten Nutzenpotenziale und etwaiger Risiken. Unter Berücksichtigung dieser Informationen sind technische, prozessuale und betriebswirtschaftliche Ziele festzulegen, die als Grundlage für eine abschließende Auswahlentscheidung zu nutzen sind (M3).

Ein zentrales Dokument dieser Phase stellt der **Anwendungssteckbrief** dar, welcher wesentliche Erkenntnisse zum adressierten Problem und zum angestrebten Lösungskonzept aufzeigt (siehe Abbildung 77). Dies umfasst Informationen zur systemtechnischen Gestaltung, den Funktionen und Einsatzbereichen der Anwendung sowie zu beabsichtigten Veränderungen und den formalisierten Zielsetzungen für die Gesamtsysteme und die einzelnen Entwicklungsstufen. Der Steckbrief dient sowohl der projektinternen Zusammenfassung als auch der Vorstellung gegenüber anderen Personen, insbesondere der Unternehmensführung. Durch eine standardisierte Darstellung ist auf dessen Basis ein Vergleich von unterschiedlichen Anwendungen und diesbezüglichen Gestaltungsoptionen möglich. Zusätzlich zu dieser prägnanten Darstellung ist die angestrebte systemseitige Gestaltung in Form eines **Lastenheftes** in dieser Phase zu dokumentieren, wobei die damit verbundene Struktur und der Detaillierungsgrad projektspezifisch zu wählen sind.

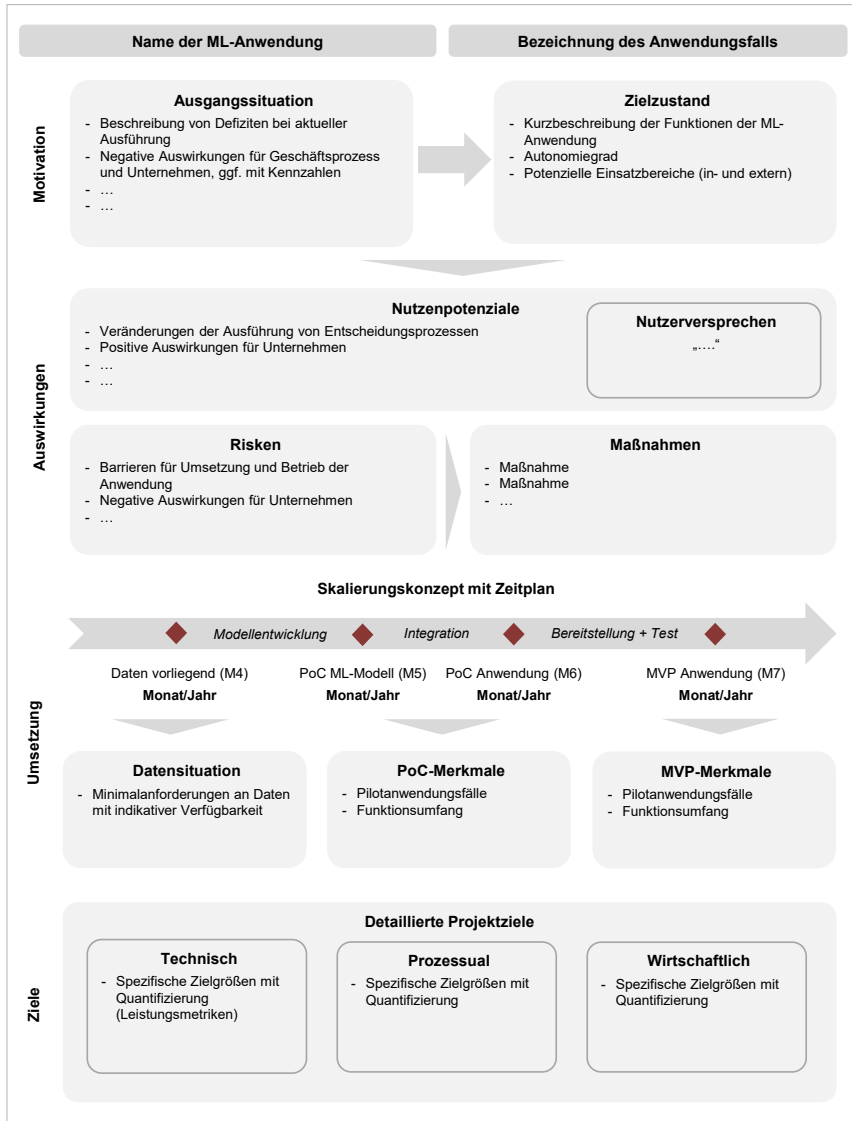


Abbildung 77: Steckbrief zur Auswahlentscheidung für ML-Anwendungen⁶⁷⁸

⁶⁷⁸ Eine Darstellung

Problemdefinition und Eignungsprüfung

Für die im Rahmen der strategischen Planung im HF Strategie identifizierten Anwendungsfälle besteht weiterhin eine Unsicherheit über deren tatsächliche Eignung für ML. Mitunter sind diese Anwendungsfälle bzw. die damit verbundenen betrieblichen Problemstellungen auch in einer ungeeigneten Form für eine Eignungsprüfung formuliert, da sie entweder bewusst oder unbewusst ungenau oder sehr aggregiert artikuliert wurden. Im Rahmen eines ersten Schrittes bedarf es daher einer **Spezifikation und Charakterisierung** des jeweils zu lösenden Problems. Die hierbei gewonnenen Informationen dienen vordergründig einer Prüfung der grundsätzlichen Eignung von ML. Sie lassen zudem den Bedarf einer notwendigen technischen Unterstützung des jeweiligen Prozesses besser erkennen.

Initial bedarf es dazu der Identifikation des jeweiligen Kernproblems und der Herstellung von Zusammenhängen mit übergeordneten betrieblichen Phänomenen. Entsprechend der häufig vorherrschenden Assoziation der wahrgenommenen Probleme mit der jeweiligen Entscheidungsausführung sind dabei auch die bisher eingesetzten Entscheidungstechniken zu erfassen. In Abhängigkeit des Abstraktionslevels des formulierten Problems ist zudem dessen Zerlegung in verschiedene Teilprobleme erforderlich, wofür analytische Methoden zur Ursachenforschung aus dem Qualitätsmanagement eingesetzt werden können, wie das **Ishikawa-Diagramm**, mit dem sich die verschiedenen Einflussfaktoren eines Problems systematisieren lassen. Das identifizierte Kernproblem ist anschließend in Form eines spezifischen logistischen Entscheidungsprozesses zu präzisieren.

Für die anschließend Charakterisierung des betrachteten Problems ist eine damit verbundene „typische“ **Entscheidungssituation zu analysieren**, wofür eine Orientierung an den Kriterien zur Qualifizierung der Komplexität von Problemen zielführend ist (siehe Kapitel 2.3.3). Eine besondere Bedeutung nimmt die Verfügbarkeit der benötigten Informationen für die Problemlösung ein, für die zu bewerten ist, ob es sich um eine deterministische oder um eine stochastische Entscheidungssituation handelt. Weiterhin ist eine Einschätzung zur Anzahl, Beziehung und Dynamik der Variablen vorzunehmen, welche für die Lösung des Problems relevant sind. Auch ist die verfügbare Zeit zur Lösungsgenerierung für eine typische Entscheidungssituation grob zu bewerten. Im Falle von Optimierungsproblemen bedarf es zudem einer Betrachtung der Anzahl und Wechselwirkungen der zu berücksichtigenden Ziele. Im nächsten Schritt sind die bestehenden **Herausforderungen bei der Ausführung des Entscheidungsprozesses** zu identifizieren, welche in Verbindung mit den ermittelten Problemmerkmalen stehen, z. B. hohe zeitliche Aufwände bei der Entscheidungsfindung oder eine geringe Qualität von Entscheidungen. Darauf basierend ist abzuleiten, welche technischen Fähigkeiten für eine Bewältigung dieser Herausforderungen benötigt werden. Die Gesamtheit an Informationen zu den vorliegenden Problemmerkmalen sowie der benötigten Problemlösungsfähigkeit ist anschließend für eine **Eignungsprüfung von ML** zu nutzen. Hierzu wird ein Rückgriff auf die Eignungsindikatoren aus Kapitel 5.5 empfohlen, welche ML-typische Ausprägungen für diese

Analysekriterien aufweisen. Das vorläufige Ergebnis der Prüfung kann auch zu einer Vorzugswürdigkeit anderer Entscheidungstechniken führen, z. B. die Umsetzung bzw. Beibehaltung von regelbasierten oder heuristischen Ansätzen.

Stand der Technik

Entsprechend der Neuartigkeit und Komplexität von ML sind bei der Umsetzung der angestrebten Anwendungen vorhandene Systeme aus der Forschung und Praxis für ähnliche Anwendungsfälle zu ermitteln. Entsprechend des geringen Umsetzungsstands im Bereich des Logistikmanagements und der dezentralen Verteilung der verfügbaren Informationen in wissenschaftlichen Datenbanken, Unternehmensberichten o. ä. geht die damit verbundene Recherche zum Stand der Technik jedoch fallweise mit einem sehr hohen Aufwand einher. Vor diesem Hintergrund wird die Nutzung der in der vorliegenden Arbeit entwickelten **Typologie für das Anwendungsspektrum von ML** in Kapitel 5 empfohlen. Durch eine Einordnung der vorab identifizierten Problemstellung in die beiden Dimensionen der Typologie kann ein schneller Überblick über bestehende „Referenzanwendungen“ gewonnen werden. Anhand der Beschreibungen der jeweils zutreffenden Typen sowie etwaig enthaltener Referenzanwendungen innerhalb ihrer Schnittmenge können unterstützende Informationen für die Konzeption und Entwicklung der angestrebten ML-Anwendung gewonnen werden. Dazu zählen u. a. Informationen zu grundsätzlich realisierbaren Systemeigenschaften sowie zu relevanten Features und Daten, zu etwaigen entwicklungsseitigen Teilproblemen, geeigneten Lernverfahren und Modellkonfigurationen. Die Einordnung in die Typologie ist gleichzeitig zu einer **Konkretisierung der Problemstellung** in Form eines ML-bezogenen Verständnisses zu nutzen. Hierbei besteht auch die Möglichkeit einer bewussten Weiterentwicklung oder Abgrenzung zu bestehenden Lösungen, was neben einer potenziellen Verbesserung der Ergebnisse auch für die Außendarstellung im Sinne eines Alleinstellungsmerkmals eingesetzt werden kann. Gleichzeitig stellt eine mögliche Zuordnung der Problemstellung zu den identifizierten Typen einen weiteren Indikator für die grundsätzliche Realisierbarkeit von ML für die jeweilige Problemstellung dar, was durch die Existenz von passenden Referenzanwendungen zusätzlich verstärkt wird. Gemeinsam mit den Erkenntnissen des vorausgehenden Schrittes ist dazu eine **Bewertung des Quality Gates M1** vorzunehmen.

Prozessanalyse

Über die allgemeine Eignung von ML hinaus ist ebenfalls die projektspezifische Datensituation zu einem frühen Zeitpunkt im jeweiligen Projekt zu bewerten. Für eine datenseitige Machbarkeitsprüfung ist initial zu bestimmen, welche Daten für die angestrebte Anwendung benötigt werden. Hierzu bedarf es wiederum eines vorausgehenden Verständnisses zu den von der jeweiligen Problemstellung adressierten Geschäftsprozessen, welches durch eine intensive **Auseinandersetzung mit den betrieblichen Abläufen** zu erzielen ist. Neben der Befragung von involvierten unternehmensinternen und -externen Akteuren, die ebenfalls im Rahmen der

Prozessanalyse zu ermitteln sind, sowie der Analyse bestehender Dokumentationen, z. B. in Form von Prozessbeschreibungen, sind auch Vor-Ort-Begehungen durchzuführen.

Initial sind die **Geschäftsprozesse**, in denen die jeweilige Problemstellung „eingebettet“ ist, aufzunehmen. Neben der Erfassung von ausführenden Aktivitäten entlang des Materialflusses umfasst dies auch dazugehörige administrative und planerische Tätigkeiten sowie begleitende Informationsflüsse. Hierbei sind auch abweichende Prozesskonfigurationen zu ermitteln, z. B. in Form regionaler und kundenseitiger Eigenarten, welche eine Grundlage für die Ableitung **unterschiedlicher Anwendungsfälle** darstellen. Die aufgenommenen Prozesse sind anschließend zu systematisieren, wofür Verfahren der Geschäftsprozessmodellierung, z. B. in Form von Business Process Model and Notation (BPMN) oder ereignisgesteuerten Prozessketten (EPK), genutzt werden können. Anhand der gewonnenen Informationen sind erste Ideen zu einer etwaigen entwicklungsseitigen **Segmentierung der Problemstellung** in mehrere Teilprobleme mit der jeweils benötigten Lernaufgabe abzuleiten, was sowohl für die nächsten Schritte als auch für die Entwicklung der Modellarchitektur in der dritten Phase benötigt wird.

Anschließend sind Einflussfaktoren der einzelnen Teilprobleme, welche relevante Features für die späteren ML-Modelle darstellen könnten, zu bestimmen. Zusätzlich bedarf es in Abhängigkeit der intendierten Lernaufgaben auch der Ermittlung der jeweiligen **Zielvariablen**. Im Falle der Features sind sowohl Faktoren aus den betrieblichen Abläufen als auch extern induzierte Einflüsse zu betrachten. Neben direkt ersichtlicher Phänomene erfordert das auch eine Ermittlung tieferliegender, tendenziell „diffuser“ Einflüsse. Vor diesem Hintergrund sind erneut Verfahren aus der Ursachenforschung zu nutzen, um komplexe Wirkungsbeziehungen systematisieren zu können, wofür sich eine **Fehlermöglichkeits- und Einflussanalyse (FMEA)** anbietet. Die Erhebung der Faktoren entspricht insgesamt einem kreativen Prozess, der in Abstimmung mit den involvierten Akteuren durchzuführen ist. Hierbei kann eine Orientierung an den Faktoren von bestehenden Referenzanwendungen aus der ML-Typologie hilfreich sein. Zur Priorisierung der nachfolgenden datenseitigen Aktivitäten ist eine indikative Bewertung der Relevanz der identifizierten Faktoren vorzunehmen.

Daten-Pre-Check

Der genaue Datenbedarf in Form der benötigten Arten, des Umfangs und der Qualität der Daten ist abhängig von der jeweiligen Modellkonfiguration und den Lernaufgaben bzw. -verfahren, welche erst final durch eine Testung verschiedener Ansätze im Rahmen der Entwicklung bestimmbar sind. Dennoch ist zu einem früheren Zeitpunkt die für das Projekt verfügbare **Datensituation indikativ zu bewerten**, um vor der Aufnahme der Entwicklung bereits Aussagen zur datenseitigen Machbarkeit der angestrebten Anwendung tätigen zu können. Auf Grundlage der Erkenntnisse dieses Daten-Pre-Checks können frühzeitig Maßnahmen zur Verbesserung der projektspezifischen Datensituation eingeleitet, aber auch die Notwendigkeit eines Abbruchs des Projektes erkannt werden.

Zu Beginn dieser Aktivitäten ist der voraussichtliche Datenbedarf für die geplante Anwendung und alle vorab ermittelten Teilprobleme zu identifizieren. Dieser bezieht sich im Wesentlichen auf die benötigten Datenarten, sollte aber auch bereits Ausprägungen zu erforderlichen Dateneigenschaften enthalten, z. B. zur Granularität und Struktur, zum Zeitraum und zur räumlichen Abdeckung. Ausgehend von der Definition eines idealtypischen Szenarios für das jeweilige Projekt sind auch **Minimalanforderungen** an den benötigten Datenbedarf abzuleiten, welche den Mindeststandard zur Entwicklung der angestrebten Anwendung determinieren. Grundsätzlich sind **Daten zu erklärenden Variablen** erforderlich, die entsprechend des jeweiligen Anwendungsfalls sehr unterschiedlich ausgeprägt sein können, z. B. in Form von Transaktions-, Stamm-, Störungs- oder Wetterdaten. Auch werden für viele Lernaufgaben **Daten zu Zielvariablen** benötigt, wozu im Kontext logistischer Entscheidungsprozesse typischerweise Informationen zum Materialfluss zählen, z. B. Bewegungs-, Prozess- oder Maschinendaten. Außerdem bedarf es fallweise auch **Zusatzinformationen**, welche einen logischen Bezug zwischen diesen Daten durch eindeutige Schlüsselvariablen herstellen. Hierzu zählen z. B. Auftragsdaten, die ein betrachtetes Objekt mittels einer Auftragsnummer entlang der Prozesskette kennzeichnen.

Der ermittelte Datenbedarf ist anschließend als Referenz für eine Analyse der aus Projektsicht verfügbaren Daten zu nutzen. Bei diesen Aktivitäten sind die Erkenntnisse zum vorab aufgenommenen Informationsfluss entlang der Prozesskette sowie zur bisherigen Nutzung von Entscheidungstechniken für die jeweilige Problemstellung zu verwenden, da diese einen Hinweis auf **existierende Datenquellen** geben können. Auch sind etwaig vorhandene Dokumentationen zur IT-Systemlandschaft einzubeziehen. Sofern zutreffend, sind grundsätzlich mehrere Datenquellen für einzelne Daten im Sinne eines „Multiple Sourcing“ zu berücksichtigen, da hierdurch spätere Plausibilitätsprüfungen und eine Kompensation von etwaigen Defiziten in den Datenquellen ermöglicht werden.

Für die verfügbaren Daten sind die Eigenschaften zum **Umfang und zur Qualität** grob zu erheben, um etwaige Einschränkungen feststellen zu können. Entsprechend der frühen Phase kann hierbei eine Fokussierung auf die gemäß der Minimalanforderungen genannten Daten eigenommen werden. Die Erhebung der benötigten Informationen ist durch die **Befragung der Dateneigentümer und -nutzer** vorzunehmen. Sofern einzelne Datensätze bereits vorliegen oder aufwandsarm beschaffbar sind, wird eine Ergänzung dieser Tätigkeiten um **explorative Datenanalysen** empfohlen, wofür jedoch auch Stichproben der Daten ausreichend sind. Die Bewertung des Datenumfangs sollte sich u. a. auf die zeitliche, räumliche und/oder prozessuale Abdeckung beziehen. Insbesondere ein kurzer verfügbarer Zeitraum kann demnach für bestimmte Lernverfahren eine Barriere darstellen. Die Bewertung der Datenqualität ist in dieser Phase auf die Vollständigkeit und Validität der jeweiligen Daten sowie deren Struktur zu beschränken, wobei insbesondere zu prüfen ist, ob es sich jeweils um Rohdaten handelt.

Im Zuge dieser Analysen sind auch die genauen Beschaffungswege für die einzelnen Daten zu ermitteln, einschließlich der jeweiligen Ansprechpartner und Dateneigentümer sowie etwaiger Restriktionen sowie **organisatorischer und technischer Barrieren**. Gleichzeitig sind auch Möglichkeiten zur Überwindung dieser Barrieren zu ermitteln, wodurch die Datensituation für das Projekt verbessert wird. Diese Erkenntnisse sind abschließend für eine Bewertung zusammenzuführen, indem die potenziell verfügbaren Daten mit ihren Qualitätseigenschaften dem zuvor ermittelten Datenbedarf gegenübergestellt werden, sodass strukturell fehlende Daten (White Spots) ersichtlich werden. Hierbei ist zu prüfen, inwiefern die formulierten Minimalanforderungen abgedeckt werden, was einer datenseitigen Machbarkeitsbewertung im Sinne des **Quality Gates M2** entspricht.

Anforderungsanalyse

Anschließend sind die Anforderungen an die Gestaltung der ML-Anwendung aus Sicht der jeweiligen Stakeholder zu ermitteln. Hierfür wird ein systematisches Vorgehen mit Orientierung am **Requirements Engineering** empfohlen (siehe Kapitel 6.1), wonach die Anforderungen durch die Einbeziehung eines breiten Spektrums an unterschiedlichen Personengruppen zu erheben, zu präzisieren und zu bewerten sind. Zum Teilnehmerkreis sollten v. a. die designierten Nutzer, aber auch Vertreter des Betriebsrats und ggf. der Rechts-, Personal- und IT-Abteilung zählen (siehe HF Aufbauorganisation). In Hinblick auf unterschiedliche Meinungen und damit verbundene Zielkonflikte ist der Erhebungsprozess durch die Projektleitung zu moderieren, sodass eine Konsensbildung zwischen den Beteiligten erreicht wird. Hierbei ist auch auf grundsätzliche Restriktionen bei der Realisierung von ML-Anwendungen hinzuweisen, um „utopischen“ Anforderungen entgegenzuwirken. Anschließend sind die ermittelten Anforderungen hinsichtlich ihrer Bedeutung zu priorisieren, um Schwerpunkte für die Entwicklung ableiten zu können. Hierzu bieten sich sowohl „pragmatische“ Scoring-Ansätze als auch spezielle Befragungstechniken an, z. B. das **Kano-Modell**, welches eine Differenzierung in Basis-, Leistungs- und Begeisterungsanforderungen vorsieht.

Neben einer offenen Erhebung der Anforderungen ist auch sicherzustellen, dass wichtige entwicklungsseitige und betriebliche Fragestellungen Berücksichtigung finden. Entsprechend ihres anwendungsübergreifenden Charakters wird dazu ein Rückgriff auf die in Kapitel 6 ermittelten Anforderungen an den Einsatz von ML im Logistikmanagement empfohlen, welche als **generische Anforderungsebenen** in Form einer Checkliste zur zielorientierten Befragung der Stakeholder genutzt werden können. Sowohl zur Konkretisierung als auch zur Ergänzung dieser Anforderungen sind fallweise weitere anwendungsspezifische Eigenschaften zu ermitteln, was insbesondere die spezifischen Funktionen der Anwendungen betrifft, z. B. die Bereitstellungsarten und -zeitpunkte der systemseitigen Ergebnisse sowie die Gestaltung einer Benutzerschnittstelle.

Potenzial- und Risikoanalyse

Im nächsten Schritt sind die Nutzenpotenziale und Risiken zu ermitteln, welche aus dem Einsatz der ML-Anwendungen für das jeweilige Unternehmen angestrebt bzw. erwartet werden. Entsprechend der Notwendigkeit einer erneuten Einbindung der einzelnen Stakeholder können diese Informationen gemeinsam mit den Anforderungen erhoben werden. Als Grundlage für diese Betrachtungen bedarf es zu Beginn einer Auseinandersetzung mit den unmittelbaren Auswirkungen der Systeme auf die Ausführung der jeweiligen Entscheidungsprozesse, wofür die in Kapitel 5.4 beschriebenen **Wirkungsdimensionen** von ML genutzt werden können. Diese umfassen u. a. eine Automatisierung, Komplexitätsreduzierung, Objektivierung und Transparenzerhöhung von Entscheidungen. Anschließend sind die denkbaren Einsatzbereiche der Anwendungen im jeweiligen Unternehmen zu bestimmen, d. h. die Gesamtheit der potenziellen Anwendungsfälle. Die unter Berücksichtigung dieser Wirkungen zu ermittelnden betriebswirtschaftlichen Potenziale können sich neben direkten finanziellen Effekten auch auf strategische, ökologische oder soziale Veränderungen, z. B. einer Verbesserung der Arbeitsbedingungen für die Mitarbeiter, beziehen. Für etwaige negative Auswirkungen sind zusätzlich Aussagen zur Eintrittswahrscheinlichkeit zu treffen. Insgesamt bedarf es bei diesen Aktivitäten einer Differenzierung nach den einzelnen Anwendungsfällen, die in Form von fallspezifischen **Potenzial- und Risikoprofilen** zusammenzufassen sind.

Zielsetzung und Auswahlentscheidung

In letzten Schritt sind die erhobenen Informationen der Analyse- und Konzeptionsphase in Form von spezifischen **Zielsetzungen** zu synthetisieren. Die Zielformulierung bezieht sich sowohl auf eine technische als auch auf eine prozessuale und betriebswirtschaftliche Dimension. Bei deren Definition sind die **SMART-Kriterien** zu berücksichtigen, nach denen die Ziele insbesondere realistisch zu wählen, spezifisch zu formulieren und größtenteils zu quantifizieren sind. Im Falle der betriebswirtschaftlichen Ziele umfasst dies zusätzlich noch die Ausweisung eines Realisierungszeitraums.

Die **technische Zieldimension** betrifft zum einen die systemtechnische Gestaltung der Anwendungen, wonach u. a. festzulegen ist, welche Funktionen – auch abseits von ML – zu realisieren sind, inwiefern die Anwendung in ein übergeordnetes System zu integrieren ist und welcher Automatisierungsgrad angestrebt wird. Der jeweilige systemseitige Zielzustand ist in Form eines **Funktionsprinzips** zu beschreiben. Zum anderen sind die Qualitäts- und Leistungseigenschaften auf Basis der ermittelten Anforderungen und unter Berücksichtigung der potenziellen projektbezogenen Realisierbarkeit zu determinieren. Hierfür bedarf es quantitativer Zielwerte, wie z. B. für die Ergebnissenauigkeit durch Angabe statistischer und/oder praxisbezogener Güteindizes. Letzteres ist entweder in Orientierung am prozessspezifischen Bedarf oder an den aktuellen Leistungen des Menschen bzw. der bereits eingesetzten Entscheidungstechniken bei der Problemlösung im Sinne einer „Baseline“ festzulegen. Die **prozessuale Zieldimension** umfasst zum einen den angestrebten Einsatzbereich, der auf Grundlage der potenziell realisierbaren Anwendungsfälle im Sinne einer „maximalen“ **Skalierung** zu

definieren ist. Zum anderen sind in diesem Kontext die intendierten Verbesserungen für die Ausführung der Entscheidungsprozesse zu formulieren, welche auf den Erkenntnissen zu den Wirkungsmechanismen der Anwendung basieren sollten. Unter Berücksichtigung der prozessualen Zielgrößen sind die angestrebten **betriebswirtschaftlichen Ziele** festzulegen, welche sich entweder auf Zielgrößen oder Leistungskennzahlen der jeweiligen Organisationseinheit oder des gesamten Unternehmens beziehen können.

Ausgehend von einer Formulierung für die final angestrebte Gestaltung der jeweiligen ML-Anwendung sind auch für die einzelnen **Entwicklungsstufen** spezifische Ziele zu definieren. Da die betriebswirtschaftlichen Zielsetzungen erstmalig im Rahmen des MVP beim Quality Gate M8 bewertet werden, betrifft dies v. a. abweichende technische und prozessuale Ziele. Ersteres kann einen reduzierten Funktionsumfang und geringere Anforderungen an die systemseitigen Qualitätseigenschaften umfassen, z. B. in Bezug auf die Ergebnisqualität und Nachvollziehbarkeit. Letzteres bezieht sich auf eine initiale Umsetzung der Anwendungen für Pilotanwendungsfälle, die aus dem gesamthaft angestrebten Spektrum auszuwählen sind. Hierzu bietet sich eine Beschränkung auf bestimmte Prozesse oder Aufträge sowie räumliche oder organisatorische Ausschnitte des gesamten Unternehmensnetzwerkes an, wie z. B. einzelne Relationen, Regionen und Standorte. Die Ziele für die einzelnen Entwicklungsstufen sowie für das finale Gesamtsystem sind in Form eines **Skalierungskonzeptes** zu konsolidieren, welches die Grundlage für die Operationalisierung der Quality Gates und damit für die Fortschrittskontrolle im Projekt darstellt.

Während die definierten Ziele primär dem projektinternen Vorgehen dienen, bedarf es für die Außenkommunikation zusätzlich einer Zusammenfassung der Verbesserungen für das Unternehmen und die Organisationsmitglieder in Form eines zentralen **Nutzenversprechens**. Dessen Kommunikation kann in Form einer „User Story“ erfolgen, bei der ein Bezug zur initial erhobenen Ausgangssituation und den damit einhergehenden Problemen hergestellt wird. Zur Ausbildung einer realistischen Erwartungshaltung sind in diesem Zusammenhang aber auch die **systemseitigen Grenzen** in Form der Funktionen und weiterer technischer Eigenschaften transparent aufzuzeigen (siehe HF Kompetenzmanagement).

Auf Grundlage der definierten Ziele – die gemeinsam mit weiteren Informationen aus dieser Phase in dem eingangs erwähnten Anwendungssteckbrief zu dokumentieren sind – ist abschließend die **Eignung der konzipierten Anwendung** für das jeweilige Unternehmen zu bewerten, was auch eine Betrachtung der Vorzugswürdigkeit gegenüber anderen Anwendungen oder Gestaltungsoptionen umfassen kann. Dies führt zu einer Entscheidung über die Umsetzung der Anwendung im Sinne des Quality Gates M3. Im Falle einer Weiterführung des Projektes sind zeitkritische Maßnahmen zur Überwindung der identifizierten Barrieren für die nachfolgenden Schritte zu initiieren, z. B. in Bezug auf die Datensituation und die IT-Infrastruktur. Außerdem ist ggf. die Projektplanung zu konkretisieren, u. a. in Hinblick auf die Laufzeit, die benötigten Ressourcen und die Kosten.

7.3.3 Vorbereitung der Datenbasis

Die Aktivitäten dieser Phase dienen der **Bereitstellung geeigneter Daten** für die nachfolgende Modellentwicklung. Neben der Identifikation und Beschaffung relevanter Daten sind diese Daten zumeist innerhalb mehrerer Schritte zur Veränderung der Struktur und der Extraktion der benötigten Inhalte aufzubereiten. Die finalen Datenbedarfe lassen sich dabei jedoch erst durch die Einbindung der Daten in die Modelle ermitteln, was insbesondere im Zusammenhang mit einem unterschiedlichen Verhalten der Lernverfahren in Bezug auf die Dateneigenschaften steht. Vor diesem Hintergrund finden die Aktivitäten dieser Phase **verzahnt mit der Entwicklung** statt. Neue entwicklungsseitige Erkenntnisse können demnach zur Beschaffung weiterer Daten und/oder zur veränderten Aufbereitung bestehender Daten führen. Insgesamt ist aufgrund der tendenziell dezentralen Verteilung und bestehender Datendefekte in der Logistik von einem hohen Aufwand für die einzelnen Aktivitäten dieser Phase auszugehen, welche in Abbildung 78 zusammengefasst sind. Branchenübergreifend nehmen diese Tätigkeiten durchschnittlich ca. 80 bis 90 % der Arbeitszeit von Data Scientists bei ML-Projekten in Anspruch.⁶⁷⁹

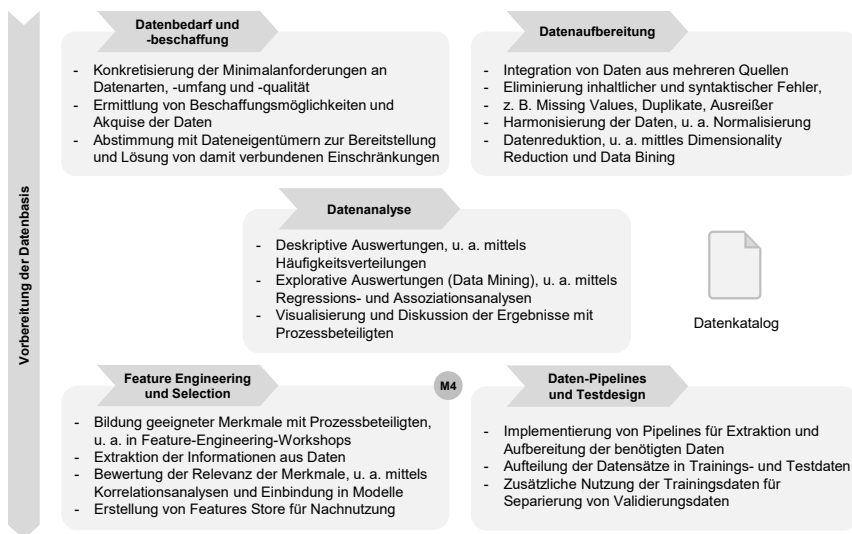


Abbildung 78: Vorbereitung der Datenbasis – Vorgehen⁶⁸⁰

Unter Berücksichtigung der Erkenntnisse aus dem Daten-Pre-Check in der ersten Phase sind die datenseitigen Minimalanforderungen zu spezifizieren. Anschließend sind die entsprechenden Daten zu beschaffen, was mit der Überwindung verschiedener formeller und technischer Barrieren verbunden sein kann. In Abhängigkeit ihrer Ausprägung sind die bezogenen Daten

⁶⁷⁹ Vgl. CrowdFlower (2016), S. 6

⁶⁸⁰ Eigene Darstellung

zu integrieren, zu bereinigen, zu harmonisieren und zu aggregieren, was außerdem deren parallele Analyse erfordert. Anhand der aufbereiteten Daten sind geeignete Features als Eingangsvariablen für die Modelle zu bilden und auszuwählen. Nach genauer Kenntnis über die für das jeweilige Projekt zur Verfügung stehenden Daten und deren Qualitätseigenschaften können Aussagen über die **datenseitige Realisierbarkeit** der angestrebten Anwendung getroffen werden (M4). Für die finalen Merkmale mit den entsprechenden Aufbereitungsschritten sind zudem Pipelines zu erstellen. Außerdem bedarf es einer Separierung der Daten in verschiedene Teilmengen für das Training und die Testung der Modelle.

Die Aktivitäten dieser Phase sind fortlaufend in einem **Datenkatalog** zu dokumentieren, welcher als Excel-Liste oder mittels Datenbanken verwaltet werden kann. In diesem Dokument sind die verfügbaren Datenquellen mit dem aktuellen Stand der Beschaffung und Aufbereitung zu pflegen. Die aufzunehmenden Informationen umfassen Angaben zur jeweiligen Art, zum Umfang und zur Qualität der Daten sowie zu den Beschaffungswegen, u. a. zu den jeweiligen Dateneigentümern, weiteren Ansprechpartnern und möglichen Einschränkungen.

Datenbedarf und -beschaffung

Der im Rahmen des Daten-Pre-Checks bereits indikativ ermittelte Datenbedarf, einschließlich der damit verbundenen **Minimalanforderungen**, ist unter Berücksichtigung weiterer nachträglich erhobener Informationen, wie den Anforderungen der Stakeholder, und in Bezug auf die ausgewählten Pilotanwendungsfälle zu konkretisieren. Dies betrifft sowohl die benötigten Daten als auch deren Eigenschaften. Demnach sind bestimmte notwendige Umfänge von zu betrachtenden Kunden, Aufträgen, Regionen oder Relationen festzulegen. In Hinblick auf den zeitlichen Umfang können grundsätzlich historische Daten für mehrere Monate bis zu einem Jahr ausreichend sein; zur Abbildung saisonaler Effekte sind jedoch tendenziell Daten für mehrere Jahre notwendig. Hinsichtlich der Granularität ist zu bewerten, ob Rohdaten benötigt werden oder auch verarbeitete Daten mit einer Beschränkung auf bestimmte Datenpunkte oder Events ausreichend sind.

Die datenseitigen Anforderungen stellen die Referenz für die anschließende Beschaffung der Daten dar. Dazu bedarf es einer intensiven Abstimmung mit den jeweiligen Prozessverantwortlichen sowie mit geeigneten Vertretern der IT, die Informationen zur Systemlandschaft der Unternehmen bereitstellen können. In diesem Rahmen sind verfügbare Systeme und Datenbanken sowie mögliche Beschaffungswege und damit verbundene **Restriktionen und Barrieren** zu ermitteln. Im Falle einer Vielzahl relevanter Systeme sowie bei der Abdeckung bestimmter Datenarten durch mehrere Datenquellen ist eine Bewertung von deren Relevanz und Verfügbarkeit für das Projekt vorzunehmen, um die Beschaffungsaktivitäten zu priorisieren. Entsprechend der identifizierten Beschaffungswege sind die benötigten Daten zu „akquirieren“, wobei die tatsächlichen Möglichkeiten zum Bezug der Daten erst bei der konkreten Anfrage und der technischen Realisierung der Datenbereitstellung sichtbar werden.

Bei der Abstimmung mit den jeweiligen Datenverantwortlichen wird eine offene Kommunikation der Projektziele und der damit verbundenen Potenziale sowie der angestrebten Datenverwendung empfohlen. Dies sollte auch einen Verweis auf die ausschließliche modellseitige Integration der Daten und den Verzicht von datenbasierten Auswertungen, z. B. in Form von Leistungskennzahlen, beinhalten. Auch besteht die Möglichkeit einer **Reduktion der Daten** um nicht benötigte, vertrauliche Informationen, z. B. um Kundendaten. Formellen Widerständen kann mit der Ausstellung von Geheimhaltungsvereinbarungen begegnet werden. Zudem können insbesondere für unternehmensexterne Akteure verschiedene Anreize zur Datenbereitstellung durch den Abschluss von projektbezogenen **Kooperationsvereinbarungen**, durch die Partizipation an den Ergebnissen oder durch eine damit verbundene finanzielle Vergütung geschaffen werden. Im Falle von fehlenden historischen Daten kann deren zukünftige Aufzeichnung bzw. Speicherung initiiert werden. Eine weitere Möglichkeit stellt die Simulation von Daten dar, wozu auch die in Kapitel 4.4.1 beschriebene **Data Augmentation** zur synthetischen Datenerzeugung und -erweiterung genutzt werden kann. Insgesamt bedarf es bei diesen Aktivitäten zur Ermittlung von geeigneten Lösungen für die Überwindung von technischen und organisatorischen Barrieren einer ausgeprägten Managementkompetenz der Projektverantwortlichen (siehe HF Kompetenzmanagement).

Datenaufbereitung

Nach Speicherung der beschafften Datensätze, z. B. mittels einer relationalen Datenbank, ist unter Rücksprache mit den Dateneigentümern und Prozessbeteiligten ein grundlegendes Verständnis zu den Daten zu entwickeln, was sowohl deren Inhalte und Struktur als auch mögliche Verbindungen zwischen den Datensätzen betrifft. Wie die Ausführungen in Kapitel 6.4.2 zeigen, weisen Daten oftmals inhaltliche und syntaktische Defizite auf, z. B. in Bezug auf deren Genauigkeit, Vollständigkeit und Konsistenz, was zu Einschränkungen bei der Leistungsfähigkeit und Güte der Anwendungen führen kann. Vor diesem Hintergrund sind die beschafften Daten in ein geeignetes Format für die Modellentwicklung zu bringen, was deren Integration, Bereinigung, Harmonisierung und Reduktion umfasst. Die Notwendigkeit einer potenziellen Datenveränderung ist jedoch stets kritisch zu prüfen, da hierdurch auch negative Effekte beim modellseitigen Lernprozess entstehen können, indem bspw. betriebliche Phänomene abweichend von der Realität interpretiert werden. Vor diesem Hintergrund erfordert dieser Schritt – neben der Verzahnung der Aktivitäten mit der Entwicklung – auch ein ausgeprägtes **betriebliches Verständnis** durch Einbeziehung entsprechender Prozessbeteiligter. Die einzelnen Aufbereitungsschritte implizieren keine verbindliche Reihenfolge, sondern können integrativ in Abhängigkeit der jeweiligen Datensituation ausgeführt werden.

Sofern einzelne Datensätze potenziell dieselben Informationen enthalten oder jeweils einen Ausschnitt eines übergeordneten Phänomens bzw. Prozesses darstellen, sind sie zu integrieren. Die Analyse dieses **konsolidierten Datensatzes** kann zur Verständnisbildung für den jeweiligen Anwendungsfall beitragen. Zudem ergibt sich dadurch die Möglichkeit einer Reduktion des Aufwands für die restlichen Aufbereitungsschritte. Die Zusammenführung der Daten

erfordert mitunter deren **Anreicherung um weitere Informationen** oder eine Erstellung von Heuristiken zur logischen Verknüpfung. Dies gilt insbesondere für Daten, in denen keine übergreifende eindeutige Schlüsselvariable, z. B. in Form einer Auftragsnummer, existiert.

Die einzelnen bzw. bereits konsolidierten Datensätze sind anschließend um **inhaltliche und syntaktische Fehler** zu bereinigen. Hierbei kann es sich um fehlerhafte Formatierungen, z. B. in Bezug auf Zeit- und Ortsangaben, sowie um inhaltliche Unstimmigkeiten einzelner Werte, z. B. falsche Zuweisungen von Merkmalen, handeln. Während diese Defekte zumeist nur durch manuelle Aktivitäten abzustellen sind, z. B. in Form eines **Relabelings**, bestehen für weitere potenzielle Fehler auch methodische Werkzeuge. Das umfasst den Umgang mit **Missing Values**, für die zuvorderst abzuwägen ist, ob der entsprechende Datensatz zu eliminieren ist. Dies ist im Falle einer deutlichen Überrepräsentation der fehlenden Werte für ein Merkmal sinnvoll, führt aber auch zu einem Datenverlust. Bei einzelnen fehlenden Werten ist daher stattdessen eine Vervollständigung der Daten anzustreben, wofür verschiedene statistische Verfahren zur Ermittlung des wahrscheinlichsten Wertes (sog. **Imputation**) zur Verfügung stehen, z. B. indem ähnliche Fälle mit vollständigen Werten betrachtet werden.⁶⁸¹ Weiterhin sind **Duplikate** in den Datensätzen, d. h. vollkommen identische und damit redundante Informationen, zu detektieren und ggf. zu entfernen. Insbesondere bei bereits integrierten Datensätzen kann es zudem vorkommen, dass sich Informationen in den Daten widersprechen, indem bspw. für ein Event zwei unterschiedliche Zeitstempel oder für ein Merkmal unterschiedliche Ausprägungen existieren. Diese Widersprüche sind ebenfalls zu beseitigen, indem die potenziell korrekten Werte durch **Plausibilitätsprüfungen** ermittelt werden, z. B. durch logische Relationen zwischen den Datenmerkmalen. Darüber hinaus sind **Ausreißer** zu detektieren, wozu es u. a. einer Analyse der Verteilung der Daten bedarf. Eine Eliminierung der dabei identifizierten Datenpunkte ist jedoch ebenfalls kritisch zu bewerten, da die Ausreißer bedeutende betriebliche Phänomene abbilden können. In Hinblick auf eine Komplexitätsreduzierung wird insbesondere für das initiale Modelltraining in der PoC-Phase eine Glättung der Daten empfohlen, wofür geeignete **Schwellwerte** aus Prozesssicht festzulegen sind.

Die bereinigten Daten sind in Hinblick auf die Modellentwicklung zusätzlich zu harmonisieren, was deren Transformation in eine geeignete Struktur durch Abstimmung von syntaktischen Unterschieden umfasst. Hierbei handelt es sich u. a. um Daten mit unterschiedlichen Einheiten für physikalische Größen, wie die Zeit oder Länge, welche in ein einheitliches Format zu überführen sind. Weiterhin ist fallweise eine **Normalisierung** der Daten vorzunehmen, bei der eine ähnliche Skalierung angestrebt wird. Der konkrete Bedarf dieser Aktivitäten hängt erneut vom gewählten Lernverfahren ab und ist bspw. bei KNN stärker ausgeprägt, da diese Lernverfahren eine geringe Robustheit bei unterschiedlich skalierten Daten aufweisen (siehe Kapitel 2.4.3.2). Für die Harmonisierung der Daten existieren verschiedene Verfahren, wozu u. a. die **z-Transformation** (sog. Z-Score) gehört.⁶⁸²

⁶⁸¹ Vgl. Sammut, Webb (2017), S. 835

⁶⁸² Vgl. Han et al. (2011), S. 114

Zur Verringerung des Aufwands für die Datenanalyse und der benötigten Rechenleistung kann zusätzlich noch eine Datenreduktion vorgenommen werden. Dies umfasst zum einen die Möglichkeit einer **Dimensionsreduktion** (siehe Kapitel 2.4.3.3), die eine Eliminierung irrelevanter oder redundanter Informationen umfasst. Dieser Ansatz steht eng im Zusammenhang mit dem Feature Engineering, indem nur diejenigen Features in den Datensätzen verbleiben, die für die Modellentwicklung benötigt werden. Aber auch weitere Informationen, die sich z. B. auf einen anderen prozessualen oder regionalen Betrachtungsbereich beziehen, können hierbei eliminiert werden. Zum anderen sind die Daten fallweise zu aggregieren, indem einzelne Datenpunkte zusammengeführt werden, wie z. B. separate Straßennamen und korrespondierende Hausnummern. Auch umfasst das eine Generalisierung der Daten, z. B. die Überführung von täglichen Daten in monatliche Daten. In diesem Zusammenhang steht auch der Ansatz der **Diskretisierung** (sog. Data Binning), welcher eine Überführung von numerischen in diskrete Daten vorsieht, indem Intervalle zur Unterteilung der Daten gebildet werden.⁶⁸³

Datenanalyse

Neben der Betrachtung einzelner Datenpunkte erfordern mehrere Aktivitäten innerhalb dieser Phase eine aggregierte Betrachtung größerer Datenausschnitte, wofür geeignete Analysen durchzuführen sind. Neben der textuellen Ausweisung der Analyseergebnisse, z. B. mittels Korrelationskoeffizienten, ist in vielen Fällen auch eine geeignete grafische Darstellung vorzunehmen. Für ein grundlegendes Verständnis zu den jeweiligen Anwendungsfällen sind initial Verfahren der **deskriptiven Statistik** einzusetzen, insbesondere zur Betrachtung von Häufigkeitsverteilungen, woraus sich Informationen zu Intervallen, Events und Kennzahlen, wie z. B. Prozessdauern, ableiten lassen. Die diesbezüglichen Ergebnisdarstellungen können u. a. mittels Dichtefunktionen, Histogrammen und Box-Plots erfolgen. Neben Erkenntnissen zu betrieblichen Phänomenen lassen sich hieraus übergreifende Aussagen zur Datenqualität ableiten, indem z. B. White Spots identifiziert werden. Zur Aufdeckung von tieferliegenden Informationen in Form von Zusammenhängen, Mustern und anderen Auffälligkeiten sind für bestimmte Datensätze zusätzliche Aktivitäten der explorativen Statistik durchzuführen, die im Kontext von größeren Datenmengen unter dem Begriff des **Data Mining** subsumiert werden (siehe Kapitel 4.4.1). Neben einem direkten Vergleich von Verteilungen kann dies u. a. die Erstellung von Regressionsanalysen und deren Visualisierung in Form von Streudiagrammen (Scatter Plots) umfassen. Darüber hinaus sind fallweise auch ML-seitige Funktionen in Form von Cluster- oder Assoziationsanalysen zu nutzen.

Feature Engineering und Feature Selection

Im nächsten Schritt sind geeignete Merkmale für die ML-Modelle zu identifizieren, wobei dies grundsätzlich möglichst viele **Merkmale mit einem hohen Einfluss** umfassen sollte und damit aber auch einen bewussten Ausschluss von irrelevanten Informationen impliziert. Neben der

⁶⁸³ Vgl. Han et al. (2011), S. 89

Reduzierung der benötigten Rechenleistung begründet sich diese Notwendigkeit insbesondere mit dem Risiko modellseitiger Fehlinterpretationen im Zuge einer steigenden Anzahl von Merkmalen, was auch als „Fluch der Dimensionalität“ bezeichnet wird⁶⁸⁴. Die Aktivitäten in diesem Schritt lassen sich daher grob in eine initiale Bildung potenzieller Merkmale (Feature Engineering) sowie in eine anschließende Bewertung zur Auswahl der relevantesten Merkmale (Feature Selection) unterteilen.

Die benötigten Merkmale müssen zur Erklärung der realen Phänomene und etwaiger Zielvariablen beitragen. Entsprechend der komplexen Ursache-Wirkungs-Zusammenhänge in der Praxis bedarf es dazu einer intensiven Auseinandersetzung mit den jeweiligen Problemstellungen, wofür auf die Erkenntnisse aus der Prozessanalyse aus der ersten Phase – ergänzt um datenanalytische Auswertungen – aufzubauen ist. Insgesamt erfordert der „kreative“ Prozess der Merkmalsbildung detailliertes Wissen zu den betrieblichen Abläufen und zu den Daten. Zum systematischen Einholen der benötigten Informationen wird die Durchführung von **Feature-Engineering-Workshops** empfohlen, an denen insbesondere Vertreter der jeweiligen Prozesse teilnehmen sollten und deren generelles Vorgehen in Tabelle 23 dargestellt ist. Zusätzlich sind im Falle bereits bestehender Modelle deren Defizite zu betrachten, um im Sinne eines iterativen Vorgehens gezielt Anpassungen an den diesbezüglichen Features vornehmen zu können.

Nr.	Zielstellung	Aktivität
1	Sammlung von potenziell relevanten Phänomenen	Vorstellung von Datenanalysen (Häufigkeitsverteilungen und explorative Auswertungen) mit Auffälligkeiten, z. B. Verteilung, Ausreißer und Korrelationen
2	Plausibilitätsprüfung der Daten und Auswertungen	Diskussion von betrieblichen Zusammenhängen sowie diesbezüglicher Abweichungen in Auswertungen, inkl. Repräsentativität der Stichprobe
3	Ermittlung von Indikatoren für Merkmale	Ermittlung von internen und externen Ursachen für Phänomene, z. B. Dispositionsregeln und externe Einflüsse
4	Bildung von entwicklungsseitig nutzbaren Merkmalen	Spezifikation bzw. Transformation der Ursachen in aussagekräftige Werte, inkl. Kernursachenanalyse
5	Priorisierung der Merkmale	Bedeutung bzw. Erklärungsgehalt der Features, inkl. merkmalsübergreifender Vergleiche zur Ermittlung von Zusammenhängen und Redundanzen
6	Prüfung der Realisierbarkeit für ML-Projekt	Ermittlung von korrespondierenden Datenquellen mit Beschaffungsmöglichkeiten und etwaigen Einschränkungen, z. B. verfügbaren Zeitraum

Tabelle 23: Ablauf eines Feature-Engineering-Workshops

Für die Bildung der entsprechenden Features ist zu prüfen, inwiefern die jeweils benötigten Informationen direkt aus den verfügbaren Daten extrahierbar sind, z. B. im Falle von Materialstammdaten oder Zeitangaben. Bei Bedarf ist auch eine **Transformation** der vorliegenden Informationen vorzunehmen, wofür verschiedene Möglichkeiten zur Verfügung stehen, u. a. die Verbindung von Werten mittels mathematischer Operationen, die Einführung von Dummy-

⁶⁸⁴ Vgl. Bellman (1966), S. 197

Variablen mittels eines binären Codings oder die Aggregation der Daten analog zur Datenreduktion, z. B. mittels einer Hauptkomponentenanalyse (PCA)⁶⁸⁵. Bei der Bestimmung der Features ist zusätzlich zu beachten, dass die entsprechenden Informationen bereits zum Zeitpunkt ihrer Verarbeitung durch die Modelle bekannt sein müssen, sodass kein sog. **Data Leakage** vorliegt. Zudem sind auch inhaltliche Verbindungen zwischen den Variablen zu überprüfen, z. B. in Form von Redundanzen und Korrelationen. Sind die benötigten Informationen bisher nicht verfügbar, bedarf es einer Beschaffung der entsprechenden Daten.

Die einzelnen Features sind anschließend in Bezug auf ihre tatsächliche Relevanz zu bewerten, um eine gezielte Eingrenzung vornehmen zu können. Hierfür sind mehrere Verfahren zu nutzen, die großenteils eine direkte Einbeziehung der Features in die Modelle erfordern. Ein der Entwicklung vorausgehender Ansatz umfasst die Ermittlung von Zusammenhängen zwischen den Merkmalen und den jeweiligen Zielgrößen mittels **Korrelationsanalysen**, wobei jedoch die Merkmale nur einzeln betrachtet werden können. Darüber hinaus ist auch der Einfluss der Merkmale auf die Ergebnisqualität der Modelle zu untersuchen, indem der jeweils resultierende „Informationsgewinn“ durch Veränderungen der einbezogenen Merkmale verglichen wird. Wie die Ausführungen in Kapitel 2.4.3.2 zeigen, kann zudem gezielt auf Lernverfahren zurückgegriffen werden, welche die Bedeutung der Features als Teil ihrer Funktion ausweisen, z. B. entscheidungsbasierte Verfahren. Auf Basis dieser Bewertungen ist entweder automatisch – wie beim letztgenannten Ansatz – oder manuell eine Übersicht zur **Feature Importance** zu erstellen, aus der die Bedeutung der Merkmale hervorgeht. Die auf dieser Grundlage final ausgewählten Merkmale sind mit den entsprechenden Daten aus den jeweiligen Datensätzen zu extrahieren, separat zu speichern und mit ihren Berechnungslogiken zu dokumentieren, um sie für den weiteren Entwicklungsprozess und für anderen Projekte im Sinne eines „**Feature Stores**“ nutzbar zu machen.

Daten-Pipelines und Testdesign

Um sowohl in der Entwicklungsphase als auch für das Re-Training der Modelle im Betrieb eine Reproduzierbarkeit der Ergebnisse sicherzustellen und den Aufwand für eine Veränderung der Datenbasis zu minimieren, z. B. durch die Erweiterung des betrachteten Zeitraums, sind die finalen datenbezogenen Aufbereitungsschritte durch die **Implementierung von Daten-Pipelines** zu automatisieren. In Anlehnung an klassische ETL-Pipelines umfasst dies eine Extraktion der benötigten Daten aus den Quellsystemen sowie deren Transformation in Form der Integration, Bereinigung, Harmonisierung und der Überführung in die festgelegten Features. Im Falle veränderter Erkenntnisse während der Entwicklungs- und Betriebsphase sind die entsprechenden Logiken anzupassen.

Zusätzlich ist für bestimmte Lerntypen ein datenbezogenes Testdesign für die Modellentwicklung zu erstellen, indem die verfügbaren Daten in **unterschiedliche Datensätze** für das Trai-

⁶⁸⁵ Vgl. Marsland (2015), S. 133 f.

ning und die finale Testung eingeteilt werden. Während die Trainingsdaten der experimentellen Entwicklung und dem initialen Lernen der Modelle dienen, ist auf Basis der unbekanntesten Testdaten die finale Güte der Modelle zu bestimmen. Aus dem Trainingsdatensatz sind fallweise zusätzliche **Validierungsdaten** zu extrahieren, welche insbesondere für die in der dritten Phase beschriebene Hyperparameteroptimierung benötigt werden. Die jeweilige Einteilung der Daten kann zufällig oder manuell nach bestimmten Kriterien erfolgen, z. B. in Hinblick auf den betrachteten Zeitraum, wobei jedoch sicherzustellen ist, dass keine größeren Unterschiede bei der Verteilung der Daten bestehen, sodass relevante Phänomene in allen Datensätzen abgebildet sind. Ein Anhaltspunkt bei der Aufteilung stellt die Nutzung von 50 % der verfügbaren Daten für das Training sowie von jeweils 25 % für die Validierung und die finale Testung dar.⁶⁸⁶ Bei vergleichsweise wenigen Daten ist dieses Verhältnis zugunsten einer Vergrößerung der Trainingsdaten zu verändern.⁶⁸⁷

7.3.4 Modellentwicklung

Mit den Erkenntnissen zum Anwendungsfall, den erhobenen Anforderungen, den darauf basierenden Zielsetzungen und den verfügbaren Daten liegen die wesentlichen Informationen für die Entwicklung der ML-Modelle vor. Mit dem Ziel einer **experimentellen Erprobung mehrerer Lösungsansätze** zur Identifikation der bestmöglichen Konfiguration sind die Entwicklungstätigkeiten, für die sich in Abbildung 79 eine zusammenfassende Darstellung findet, sowohl für das jeweilige Gesamtmodell als auch für etwaige Teilprobleme bzw. -modelle iterativ zu durchlaufen.

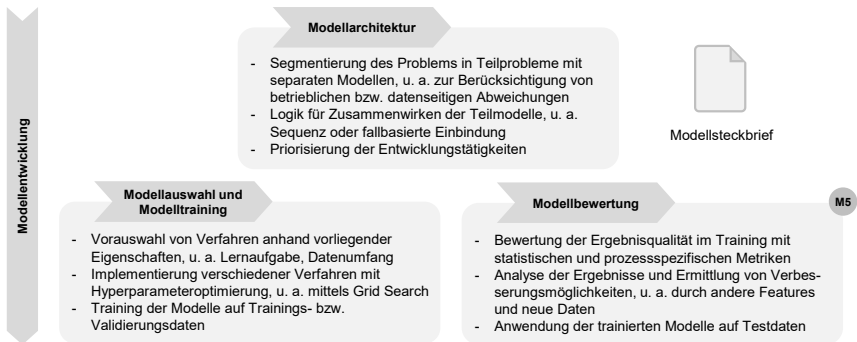


Abbildung 79: Modellentwicklung – Vorgehen⁶⁸⁸

Die Entwicklungsaktivitäten in dieser Phase beginnen mit der Konzeption einer geeigneten Architektur für die zu modellierenden Teilprobleme. Unter dieser Vorgabe ist die Implementierung der einzelnen Modelle vorzunehmen, was die Schritte einer Modellauswahl (Model

⁶⁸⁶ Vgl. Hastie et al. (2009), S. 222

⁶⁸⁷ Vgl. Marsland (2015), S. 21

⁶⁸⁸ Eigene Darstellung

Selection), d. h. die Implementierung der Lernverfahren mit einer geeigneten Parametrisierung, eines begleitenden Trainings der Modelle mit einer Bewertung der Zwischenergebnisse (Model Evaluation) sowie einer finalen Testung der Modelle (Model Validation) umfasst. Beim Erreichen der Ziele des Quality Gates M5 im Rahmen dieser „Offline-Testungen“ ist die technische Machbarkeitsprüfung der ML-Modelle für den initial anzustrebenden PoC abgeschlossen. Die einzelnen Aktivitäten sind jedoch im Falle von modellseitigen Anpassungsbedarfen bei der Erweiterung der Modelle um weitere nicht ML-spezifische Funktionen (M6) sowie bei deren Überführung in den produktiven Betrieb und der damit verbundenen „Online-Testung“ (M7 bis M9) erneut auszuführen.

Das zentrale Ergebnis dieser Phase in Form der finalen ML-Modelle ist in einem **Modellstreckbrief** zu dokumentieren, welcher bedeutende entwicklungs- und datenseitige Informationen enthält, u. a. die verwendete Modellarchitektur, die eingesetzten Lernverfahren, Parametereinstellungen, Features und Daten sowie die realisierten Bewertungsergebnisse in Bezug auf die geforderten Zielgrößen. Darüber hinaus sind auch identifizierte Verbesserungsmöglichkeiten für die Modelle zu vermerken, die aufgrund fehlender Ressourcen oder anderer Barrieren nicht realisiert werden konnten – allerdings einen Ansatzpunkt für die nachfolgenden Entwicklungsschritte darstellen.

Modellarchitektur

Auf Grundlage der prozessualen und datenbezogenen Erkenntnisse aus den ersten beiden Phasen ist ein geeignetes Konzept für die Modellarchitektur zu entwerfen. Dies umfasst eine etwaige **Segmentierung des Gesamtproblems** in Teilprobleme sowie die Entwicklung einer Logik für deren Zusammenwirken innerhalb eines Gesamtmodells. Die ersten diesbezüglichen Überlegungen sind vor der Implementierung anzustellen und im Zuge der Modelltestung sowie neuer entwicklungsseitiger Erkenntnisse anzupassen. Sie dienen dabei auch einer anfänglichen Strukturierung und **Priorisierung der entwicklungsseitigen Tätigkeiten**. Die Segmentierung kann sowohl in Form einer sequenziellen Zerlegung des Gesamtproblems als auch durch die fallweise Unterscheidung vorgenommen werden. Zudem ist auch eine Kopplung bei-der Ansätze möglich.

Die Vorteilhaftigkeit von mehreren Teilmodellen gegenüber einer holistischen Lösung kann in mehreren Fällen gegeben sein. Hierzu gehören bspw. verschiedene Ausprägungen der betrachteten Anwendungsfälle, z. B. in Bezug auf die abgedeckten Regionen oder Aufträge, welche **abweichende betriebliche Rahmenbedingungen** und damit auch unterschiedliche Merkmale und/oder Zielvariablen aufweisen. Selbiges trifft auf eine Zusammensetzung der adressierten Problemstellungen bzw. der zugrundeliegenden Geschäftsprozesse aus mehreren betrieblichen „Einheiten“ zu, z. B. in Form von Teilprozessen oder Akteuren in einer Logistikkette. Neben den genannten betrieblichen Unterschieden kann auch eine abweichende Datenverfügbarkeit in diesen Einheiten und Anwendungsfällen eine Unterteilung in Teilprobleme motivieren, um gezielt unterschiedliche Lernverfahren einzusetzen. Darüber hinaus beeinflusst

sen auch technische Voraussetzungen die Gestaltung der Modellarchitektur, z. B. in Form einer geringen Rechenleistung, was tendenziell gegen eine Nutzung von mehreren Teilmodellen spricht. Auch die Realisierung einer Aktualisierbarkeit der Modelle stellt einen Grund für eine Segmentierung dar.

Modellauswahl und Modelltraining

Gemäß der festgelegten Architektur sind die ML-Modelle zu entwickeln, wozu die für die jeweilige Problemstellung geeignetsten Lernverfahren mit der optimalen Parametrisierung zu ermitteln und in ein Gesamtmodell zu integrieren sind. Zur Prüfung der Ergebnisse sind die implementierten Modelle für jedes Teilproblem auf die zuvor extrahierten **Trainingsdaten** anzuwenden. Anstatt der Entwicklung eines individuellen Algorithmus kann hierzu in den gängigen Entwicklungsumgebungen auf ein Vielzahl von Lernverfahren mittels vordefinierter Funktionen zurückgegriffen werden, die individuell zu konfigurieren sind.

Für die Lösung der jeweiligen Probleme sind mehrere Lernverfahren zu implementieren und hinsichtlich ihrer Eignung durch eine Testung der Modelle zu bewerten. Um den damit verbundenen Aufwand zu reduzieren, wird eine gezielte **Vorauswahl von potenziell geeigneten Verfahren** anhand der Gegenüberstellung der fallspezifischen Anforderungen und der typischen Eigenschaften der Lernverfahren empfohlen (siehe Kapitel 2.4.3). Dies betrifft zuvorderst die zu realisierende Lernaufgabe, z. B. in Form einer Regression, Klassifikation oder Gruppierung, nach der sich die infrage kommenden Verfahren eingrenzen lassen. Auch bestehen hinsichtlich der Fähigkeit zum Umgang mit großen bzw. kleinen Datenmengen Unterschiede zwischen den Verfahren. Selbiges gilt für den Umgang mit Rauschen und heterogenen Formaten von Variablen. Zudem sind die individuellen Zielsetzungen aus der ersten Phase zu betrachten, die z. B. einen tendenziell nachvollziehbaren Lösungsweg erfordern können, z. B. durch die Ausgabe einer Feature Importance, was ebenfalls die geeigneten Verfahren einschränkt. Einen weiteren Indikator für die Vorauswahl stellen bestehende Anwendungen mit ähnlichen Problemstellungen dar, wie sie ebenfalls in der ersten Phase anhand der ML-Typologie identifiziert wurden. Gleichzeitig ist hierbei auch eine bewusste Abgrenzung durch die Auswahl neuer Ansätze möglich.

Im Sinne einer integralen Aktivität bei der Erprobung der einzelnen Verfahren ist auch eine Konfiguration von deren Hyperparametern vorzunehmen, die einen hohen Einfluss auf den Lernprozess nehmen (siehe Kapitel 2.4.3.2). Für die sog. **Hyperparameteroptimierung** („Model Tuning“) wird ein Rückgriff auf verschiedene technische Instrumente empfohlen, da hierdurch die Ausprägungsmöglichkeiten mit den jeweiligen Wechselwirkungen der einzelnen Hyperparameter besser erfasst werden können. Neben der Anwendung von Optimierungsmethoden, wie der Bayes'schen Optimierung, und der zufälligen Kombination von verschiedenen Konfigurationen mittels der sog. Random Search stellt v. a. die **Rastersuche** (Grid Search) einen geeigneten Ansatz dar, bei dem ausgehend von einer manuellen Eingrenzung des Wertebereiches für die Parameterausprägungen automatisch die optimale Konfiguration ermittelt

wird.⁶⁸⁹ Entsprechend der Ausführungen zum Testdesign in der zweiten Phase bietet sich für die Validierung der Hyperparameteroptimierung eine weitere Aufteilung der Trainingsdaten in Datensätze zum Training und zur Validierung an. Auch hierfür existieren verschiedene Verfahren mit unterschiedlichen Logiken, die von einer manuellen bis zu einer automatisierten Ausführung reichen. Ein geeignetes Verfahren, welches auch bei der Grid Search Anwendung findet, ist die **die k-fache Kreuzvalidierung** (k-fold Cross-Validation), bei der die Aufteilung der Daten nicht statisch, sondern iterativ anhand verschiedener Kombinationen erfolgt, sodass alle Fälle in den Daten einmal für das Training und die Validierung verwendet werden.⁶⁹⁰

Modellbewertung

Für die Auswahl der optimalen Modellkonfiguration sind die einzelnen Ergebnisse im Rahmen des Trainings miteinander zu vergleichen. Die damit verbundene Bewertung muss sich an den in der ersten Phase festgelegten Zielen gemäß der Quality Gates – beginnend bei M5 für den PoC – orientieren, was im Falle der **Ergebnisqualität** verschiedene statistische Metriken und ggf. problemspezifische Kennwerte umfassen kann. Neben der Ermittlung von deren Ausprägung ist zur Diskussion der Ergebnisse eine zusätzliche grafische Darstellung vorzunehmen. Die erzielten Ergebnisse sind anschließend kritisch in Hinblick auf modellseitige Stärken und Schwächen sowie die **Ableitung möglicher Verbesserungen** zu analysieren, wofür ebenfalls die jeweiligen Prozessbeteiligten einzubeziehen sind. Neben der Betrachtung von aggregierten Indikatoren, wie der Verteilung der Testfälle und der Feature Importance, die einen Hinweis auf die Abdeckung bestimmter betrieblicher Phänomene geben, ist bei der Analyse auch ein Rückschluss auf Einzelfälle in den Daten zu ziehen. Demnach sind insbesondere Ausreißer der Modelle zu betrachten, da diese potenzielle Fehlerquellen darstellen. Zudem sind Vergleiche zwischen den einzelnen Lösungsansätzen und vorausgegangenen Modellversionen anzustellen. Bei den zu ermittelnden Verbesserungen kann es sich u. a. um Anpassungen der gewählten Modellarchitektur, den eingesetzten Lernverfahren und deren Konfiguration sowie um datenseitige Aktivitäten, wie die Eliminierung von detektierten Datenfehlern, die Anpassung der Merkmale und auch die Beschaffung weiterer Daten handeln. In Abhängigkeit der bereits realisierten Zielerfüllung und einer Aufwand-Nutzen-Abschätzung sind ausgewählte Maßnahmen zu initiieren. Neben einer direkten Verbesserung der Modelle dienen die Erkenntnisse auch dem weiteren Entwicklungsprozess und zukünftigen Vorhaben.

Die trainierten Modelle sind anschließend auf die **Testdaten** anzuwenden, welche einen produktiven Betrieb simulieren, indem die darin enthaltenen Fälle den Modellen unbekannt sind, sodass Aussagen zu deren Generalisierbarkeit getroffen werden können. Wird nach der Ergebnisanalyse ebenfalls eine Erfüllung der definierten Ziele festgestellt, gilt die Modellentwicklung als abgeschlossen. In allen anderen Fällen bedarf es einer entwicklungsseitigen Anpassung.

⁶⁸⁹ Vgl. Liashchynskyi (2019), S. 3

⁶⁹⁰ Der Parameter „k“ steht für die Anzahl der zu bildenden Teilmengen der Daten. Vgl. Hastie et al. (2009), S. 241

sung entsprechend der definierten Verbesserungsmöglichkeiten. Sind diese bereits ausgeschöpft oder aus anderen Gründen nicht realisierbar, ist die technische Machbarkeit des Entwicklungsansatzes infrage zu stellen und über einen Abbruch des Projektes zu entscheiden.

7.3.5 Betriebliche Einführung

Im Rahmen dieser Phase sind die prototypischen ML-Modelle in den Betrieb zu überführen, um sie produktiv für die Ausführung bzw. Unterstützung von Entscheidungsprozessen nutzen können. Ausgehend von einer weiterhin reduzierten Systemgestaltung zielen diese Aktivitäten, welche in Abbildung 80 zusammenfassend dargestellt sind, auch auf eine funktionale und prozessuale Erweiterung der angestrebten ML-Anwendung gemäß des initial festgelegten Skalierungskonzeptes ab. Einige der Aktivitäten gelten darüber hinaus für den gesamten Lebenszyklus der Anwendungen. Neben etwaigen Änderungsbedarfen an den ML-Modellen, die im Rahmen der Operationalisierung festgestellt werden und zu einer Iteration der Entwicklungsschritte der zweiten und dritten Phase führen, ist das Vorgehen dieser Phase stark von „klassischen“ IT-Aktivitäten zur Entwicklung und zum Betrieb von Software geprägt. Die Verzahnung dieser entwicklungsseitigen und betrieblichen IT-Aktivitäten ist durch die Nutzung von Methoden und Werkzeugen des **DevOps-Ansatzes** zu unterstützen, wozu u. a. die im weiteren Verlauf vorgestellten CI/CD-Pipelines gehören.⁶⁹¹



Abbildung 80: Betriebliche Einführung – Vorgehen⁶⁹²

⁶⁹¹ CI (Continuous Integration) und CD (Continuous Delivery bzw. Continuous Deployment) sind Konzepte zur Automatisierung von Aktivitäten der Entwicklung und des Betriebs von Anwendungen. Während CI das Testen und Validieren von Modellen umfasst, beinhaltet CD die Bereitstellung der Modelle für den produktiven Einsatz. Vgl. Senapathi et al. (2019), S. 62

⁶⁹² Eigene Darstellung

Zu Beginn der produktiven Überführung sind die entwickelten Modelle in ein Gesamtsystem in Form der angestrebten ML-Anwendung zu integrieren (M6). Diese Anwendung ist anschließend mit einem reduzierten Funktionsumfang in Sinne eines MVP in der jeweiligen Zielumgebung bereitzustellen (Deployment). Dies umfasst u. a. die Realisierung eines Re-Trainings der Modelle auf Basis einer aktualisierten Datenbasis, wobei Voraussetzungen für eine (teil-)automatische Ausführung dieser Aktivitäten zu schaffen sind. Im Rahmen des betrieblichen Einsatzes sind sowohl die technische Realisierbarkeit (M7) als auch die prozessualen und betrieblichen Auswirkungen (M8) zu überprüfen. Im Falle einer stabilen Erreichung dieser Ziele ist die ML-Anwendung anschließend um die weiteren festgelegten Funktionen und Anwendungsfälle zu erweitern, was deren finaler Einsatzfähigkeit entspricht (M9).

Vor der Implementierung sind die Erkenntnisse zur systemseitigen Gestaltung der angestrebten Anwendungen, welche innerhalb der beiden vorausgegangenen Phasen gewonnenen wurden und Implikationen für die produktive Umsetzung haben, zu konsolidieren. Dies umfasst u. a. die benötigten Daten zu den relevanten Input- und Output-Systemen, den damit verbundenen Datenumfang sowie die benötigte Rechenleistung und Speicherkapazität. Die Informationen sind in dem initial erstellten **Lastenheft** zu dokumentieren, wobei die darin enthaltenen Festlegungen zu erweitern und ggf. anzupassen sind.

Systemintegration

Im ersten Schritt sind die ML-Modelle in ein übergeordnetes Gesamtsystem in Form der ML-Anwendung zu integrieren. Gemäß des in der ersten Phase festgelegten Funktionsprinzips kann dies eine **Verbindung der Modelle mit anderen Software- und Hardwarekomponenten** erfordern, welche weitere Funktionen bereitstellen, wozu auch Interaktionsmöglichkeiten mit den Nutzern gehören. Die Implementierung dieser Komponenten ist größtenteils parallel zu der Modellentwicklung vorzunehmen. Daher umfasst dieser Schritt insbesondere die Ausführung von offenen Entwicklungstätigkeiten für die Komponenten, welche aufgrund einer technischen Abhängigkeit zu den ML-Modellen noch nicht finalisiert werden konnten, sowie die Realisierung einer übergreifenden Steuerlogik und eines Datenaustauschs zwischen den einzelnen Komponenten, u. a. durch die Programmierung von Schnittstellen. Die Funktionalität der realisierten Systeme ist anschließend durch Testungen unter Offline-Bedingungen in Bezug auf die Ziele des Quality Gate M6 zu überprüfen.

Bereitstellung in Zielumgebung

Anschließend sind die als PoC realisierten ML-Anwendungen in die produktive Zielumgebung zu überführen. In Abhängigkeit vom jeweiligen Funktionsumfang wird bei diesen Aktivitäten eine erneute Beschränkung auf die ML-basierten Funktionen und eine Umsetzung für die Pilotanwendungsfälle zur Komplexitätsreduzierung empfohlen. Eingangs sind dazu die erforderlichen **Schnittstellen** zur Realisierung des Datenaustauschs mit den IT-Systemen für den In- und Output zu implementieren. Da die Echtzeitdaten von den bisher betrachteten historischen Daten abweichen können, bedarf es zudem eines Abgleiches von deren Inhalt und Struktur.

Dies umfasst auch eine Klärung etwaiger sicherheitsrelevanter Fragen, die sich aus einer bisherigen Eliminierung von bestimmten Informationen in den historischen Daten ergeben. Weiterhin bedarf es der Einrichtung einer **Infrastruktur** für die Ausführung der Anwendungen und deren Datenspeicherung entsprechend der benötigten Anforderungen (siehe HF Datenmanagement). Eine weitere Aktivität betrifft das **Re-Training** der Anwendungen bzw. der zugrundeliegenden ML-Modelle. Gemäß den Ausführungen in Kapitel 6.2.3 ergeben sich hierfür verschiedene Möglichkeiten, die von einer unregelmäßigen bis zu einer kontinuierlichen Aktualisierung reichen. Zu deren Realisierung sind die gesamten daten- und entwicklungsseitigen Schritte von der Extraktion und Aufbereitung der Echtzeitdaten bis zum Training der Modelle, einschließlich der Hyperparameteroptimierung und Testung, zu automatisieren. Für die Implementierung dieser **Trainings-Pipeline** ist auf die bereits bestehenden Daten-Pipelines und die damit verbundenen Aufbereitungslogiken aus der Modellentwicklung aufzusetzen.

Beim anfänglichen betrieblichen Einsatz der Anwendungen sowie grundsätzlich bei kritischen Entscheidungsprozessen bietet es sich an, die Kontrolle und die diesbezügliche Freigabe der jeweiligen Modellaktualisierungen weiterhin manuell auszuführen. Im Falle eines zunehmenden Verständnisses über das Verhalten der Modelle kann jedoch zur Aufwandsreduzierung auch dieser letzte Schritt des Re-Trainings automatisiert werden. Die damit verbundene Automatisierung der gesamten Aktivitäten von der Datenextraktion über die Entwicklung der Modelle bis zu deren betrieblicher Bereitstellung ist durch die Implementierung einer **CI/CD-Pipeline** zu realisieren und betrifft insbesondere Anwendungsfälle mit sehr dynamischen Einflüssen. Trotz der manuellen oder automatischen Kontrolle der jeweils aktualisierten Modelle wird die Nutzung von unterstützenden Bereitstellungsstrategien empfohlen, die entweder einen sukzessiven Modellwechsel, wie das **Canary-Deployment**, oder einen Rückgriff auf bestehende Modellversionen durch deren parallelen Betrieb ermöglichen, wie das **Blue-Green-Deployment**⁶⁹³.

Test und Monitoring

Die realisierten Anwendungen sind unter den produktiven Bedingungen und der Verarbeitung von Echtzeitdaten zu prüfen. Dies erfordert einen **befristeten Testbetrieb** unter menschlicher Kontrolle zur Sicherstellung der benötigten technischen Eigenschaften sowie der angestrebten prozessualen und betriebswirtschaftlichen Auswirkungen (M8). Ersteres sollte dabei über die bisher fokussierte Ergebnisqualität hinausgehen und auch eine Bewertung weiterer Eigenschaften, wie die Verfügbarkeit, Sicherheit und Compliance, umfassen. Die Prüfung der Nutzenpotenziale kann u. a. Zeitmessungen und Kostenbewertungen beinhalten. Ein besonderes Augenmerk ist hierbei auf die **Interaktion zwischen den Systemen und den Nutzern** zu legen, um Veränderungen bei der Ausführung der Entscheidungsprozesse bewerten zu können. Die Erhebungszeiträume beider Bewertungsdimensionen sollten wenige Wochen bis mehrere Monate umfassen, können aber in Abhängigkeit der Zielgrößen auch variieren. Über

⁶⁹³ Vgl. Khan et al. (2021), S. 215 f.

diese zeitlich begrenzte Testung hinaus ist insbesondere für die Sicherstellung der Ergebnisqualität – aufgrund des dynamischen Systemverhaltens sowie für die Beobachtungen etwaig erkannter Schwachstellen – eine **permanente Kontrolle** der Anwendungen im laufenden Betrieb sicherzustellen. In Abhängigkeit des angestrebten Autonomiegrads erfordert dieses Monitoring weiterhin eine intensive Einbeziehung der Menschen, wobei diese durch systemseitige Kontrollmechanismen zu unterstützen sind. (siehe HF Mensch-Computer-Interaktion).

Skalierung

Nach Erreichung der angestrebten prozessualen und betriebswirtschaftlichen Ziele entsprechend des Quality Gates M8 sind die Anwendungen gemäß des initial festgelegten Skalierungskonzeptes zu erweitern. Dies betrifft die finale **Implementierung weiterer Funktionen**, die aufgrund der Beschränkung auf die ML-basierten Funktionen bei der Umsetzung des MVP nicht weiterentwickelt wurden. Außerdem sind die Anwendungen auf weitere definierte **Anwendungsfälle zu übertragen**. Insbesondere Letzteres kann umfassende Modellanpassungen und damit eine Iteration der daten- und entwicklungsseitigen Aktivitäten erfordern. Die prozessual und funktional skalierten Anwendungen sind erneut unter Online-Bedingungen zu testen, wobei die Kriterien des Quality Gates M9 zu berücksichtigen sind. Eine entsprechende Zielerfüllung stellt den Übergang von einem MVP in ein vollständig einsatzfähiges System dar, welches unternehmensintern und ggf. -extern ohne Einschränkungen genutzt werden kann.

Optimierung

Über die Bewertung der Kriterien der einzelnen Quality Gates hinaus ist im Rahmen des produktiven Einsatzes der Anwendungen das Verständnis über deren Verhalten zu vertiefen. Dazu bedarf es gezielter Analyse der systemseitigen Ergebnisse, was u. a. einen Vergleich von unterschiedlichen Entscheidungs- bzw. Datensituationen und einer Identifikation technischer Ursachen umfasst. Die erzielten Erkenntnisse dienen einer verbesserten Qualitätskontrolle durch die Nutzer, welche dadurch für die Fähigkeiten und Grenzen der Systeme sensibilisiert werden (siehe HF Kompetenzmanagement). Analog zum Vorgehen bei der Modellentwicklung sind diese Erkenntnisse zudem für die Ableitung von geeigneten Anpassungsmöglichkeiten einzusetzen. Durch eine Verstetigung dieser Aktivitäten ist im laufenden Betrieb eine **kontinuierliche Verbesserung** der Anwendungen bzw. der zugrundeliegenden Modelle zu etablieren. Hierbei sind auch externe Impulse zu nutzen, wozu u. a. eine regelmäßige Recherche nach neuen Lösungsansätzen in Forschung und Praxis zählen. Im Falle modellseitiger Anpassungen bedarf es zur Prüfung von deren Vorzugswürdigkeit gegenüber den bestehenden Modellversionen eines erneuten Durchlaufens der vorausgegangenen daten- und entwicklungsseitigen Schritte. Vor diesem Hintergrund sind die identifizierten Verbesserungsmaßnahmen stets kritisch hinsichtlich ihres potenziellen Mehrwertes zu bewerten.

7.3.6 Validierung

Für die finale Entscheidung über die Nutzung von ML zur Realisierung der angestrebten Prognoseanwendung im ETA-Anwendungsfall und für den anschließenden Umsetzungsprozess muss das hierfür gebildete „ETA-Projekt“ verschiedene Quality Gates passieren, welche im Folgenden mit den korrespondierenden Aktivitäten beschrieben sind.

M1 – Eignungsprüfung: Ausgehend von einer groben Problemerkfassung und indikativen Zuordnung der ML-Technologie zur Lösung des ETA-Anwendungsfalls im Rahmen der strategischen Planung werden zu Beginn des Umsetzungsprozesses die damit verbundenen Aktivitäten intensiviert. Dies beinhaltet eine Erfassung des Kernproblems, bei der erkannt wird, dass die bisherigen Entscheidungsprozesse für eine Ermittlung von Prozess- bzw. Ankunftszeiten zukünftiger Transporte von einer hohen Unsicherheit geprägt sind. Diese Unsicherheit ist auf eine Vielzahl von Störungen bzw. Einflussfaktoren auf die Prozesse zurückzuführen. Weder die Mitarbeiter auf Basis ihrer Erfahrungen – die häufig zu Über- oder Unterschätzungen von Störungsereignissen führen – noch die eingesetzten Entscheidungstechniken, bei denen es sich um einfache Heuristiken zur linearen Fortschreibung von Verspätungen handelt, sind in der Lage, diese Faktoren bei der Ermittlung zukünftiger Transportverläufe adäquat zu berücksichtigen. Dies führt zu nicht optimalen, d. h. fehlerhaften und isolierten, Dispositionsentscheidungen, zu einem hohen Aufwand in der Transportplanung und -steuerung sowie zu einer schlechten Planbarkeit für alle assoziierten Geschäftsprozesse, wie z. B. die Ressourcenplanung. Vor diesem Hintergrund wird eine Entscheidungstechnik benötigt, welche grundsätzlich die Fähigkeit zur zuverlässigen Ermittlung zukünftiger Prozesszeiten aufweist. Hierdurch soll eine vorausschauende Planung mit faktenbasierten Entscheidungen ermöglicht werden.

Die Analyse einer in diesem Kontext typischen Entscheidungssituation zeigt, dass die vielfältigen Einflussfaktoren eine hohe Dynamik mit komplexen Wirkungsbeziehungen aufweisen, wie z. B. das räumliche „Fortpflanzen“ von Verspätungen im Netzwerk. Ergänzend zu dieser stochastischen Entscheidungssituation sind die Entscheidungen aufgrund ihres unmittelbaren Bezuges zur logistischen Leistungserstellung in sehr regelmäßigen Abständen zu treffen, was in einer geringen verfügbaren Zeit für die Entscheidungsträger bei der Ermittlung der auftragspezifischen Prozesszeiten führt. Die benötigte Entscheidungstechnik muss demnach mit dieser Problemkomplexität umgehen können und eine permanente Ausführung mit einer dynamischen Anpassung der Ergebnisse ermöglichen.

Bei der Einordnung des vorliegenden Entscheidungsproblems in die entwickelte ML-Typologie ergibt sich das Transportmanagement als korrespondierender Typ für den logistischen Anwendungsbereich, welcher sich u. a. durch die Einbeziehung von externen Daten auszeichnet (siehe Kapitel 5.2.2.5). In Bezug auf die Typen der Problemlösungsfähigkeit erfolgt eine Zuordnung zur Prognose (siehe Kapitel 5.2.1.3). Nach Kombination der beiden Typenarten findet sich für das Transportmanagement-Prognose-Tupel mit der Veröffentlichung von *Owczarek, Janke (2018)* eine bestehende Referenzanwendung, bei der ebenfalls Verspätungen von mehrstufigen Transportprozessen prognostiziert werden (siehe Tabelle 35 im Anhang). Über

die typenbezogenen Informationen zur generischen Realisierung der Prognosefähigkeit hinaus können daher in diesem Fall anwendungsspezifische Erkenntnisse weitergenutzt werden. Demnach wurde in der Referenzanwendung für das Problem eine Klassifikation umgesetzt und mit dem Lernverfahren Random Forest die höchste Prognosegüte erzielt.

Sowohl die vorliegenden Problemmerkmale als auch die benötigte Problemlösungsfähigkeit sprechen gemäß den Indikatoren in Kapitel 5.5 für eine Eignung von ML zur Realisierung der ETA-Anwendung. Die Vorzugswürdigkeit dieses Ansatzes gegenüber modellgestützten Entscheidungstechniken ergibt sich dabei insbesondere aus der festgestellten Dynamik der Einflussfaktoren. Die Möglichkeit der Zuordnung zu der entwickelten ML-Typologie sowie die Existenz bestehender Referenzanwendungen bekräftigen diese Einschätzung zur Eignung, so dass das Quality Gate M1 passiert werden kann.

M2 – Daten-Pre-Check: Neben der grundsätzlichen Eignung der Problemstellung für den ML-Ansatz wird auch die datenseitige Realisierbarkeit für das ETA-Projekt bewertet. Als Grundlage für die Bestimmung der benötigten Daten erfolgt dazu eine Analyse des prozessualen Betrachtungsbereiches und die Ermittlung relevanter Variablen für die ML-Modelle. Der betrachtete Prozess der maritimen Distribution im ETA-Anwendungsfall beginnt mit der Gestaltung der Container im Werk zur Verladung der Güter und endet mit deren Verladung auf ein Seeschiff. Es zeigt sich, dass verschiedene Konfiguration dieses Prozesses existieren, die sich insbesondere in der Nutzung verschiedener Verkehrsträger unterscheiden. Der reine Straßentransport und der intermodale Straße-Schiene-Transport – im Sinne eines kombinierten Verkehrs (KV) – weisen dabei die höchsten Gütermengen auf. Bei einer feingranularen Betrachtung dieser Prozesskette ergeben sich verschiedene Teilprozesse, die im Falle des intermodalen Transports u. a. auch Umschlagsprozesse in einem KV-Terminal umfassen. Entsprechend des mehrstufigen Charakters sind sowohl unternehmensintern als auch -extern verschiedene Akteure in die logistische Leistungserstellung involviert. Dazu gehören neben Terminalbetreibern im Seehafen und Hinterland auch Eisenbahnverkehrsunternehmen (EVU) und Eisenbahninfrastrukturunternehmen (EIU) sowie Spediteure und KV-Operateure. Die Vertreter all dieser Unternehmen kommen als potenzielle Wissensträger und Eigentümer relevanter Daten infrage, sodass versucht wird, diese in das ETA-Projekt miteinzubeziehen.

Im Rahmen der Prozessanalyse werden auch größere betriebliche Unterschiede zwischen den einzelnen Teilprozessen mit Implikationen auf die Datenbeschaffung und die Modellkonfiguration festgestellt. Dies betrifft neben den wirkenden Einflussfaktoren auch die relevanten Zielvariablen. Gemeinsam mit den jeweiligen Prozess- und Datenverantwortlichen werden die benötigten und verfügbaren Daten für den Anwendungsfall identifiziert, wobei zu diesem Zeitpunkt lediglich eine Differenzierung nach drei Datenarten in Form von Ist- und Sollinformationen zu den Prozessen (Bewegungsdaten) sowie von Daten zur Qualifizierung der Soll-Ist-Abweichungen (Störungsinformationen) vorgenommen wird. Auch bei der Verfügbarkeit und Qualität dieser Daten lassen sich erhebliche Unterschiede zwischen den Teilprozessen feststellen. Während der Schienentransport für alle Datenarten eine hohe Abdeckung aufweist,

sind für die Rangierprozesse in den KV-Terminals und den Seehäfen nahezu keine Informationen vorhanden (siehe Abbildung 81).

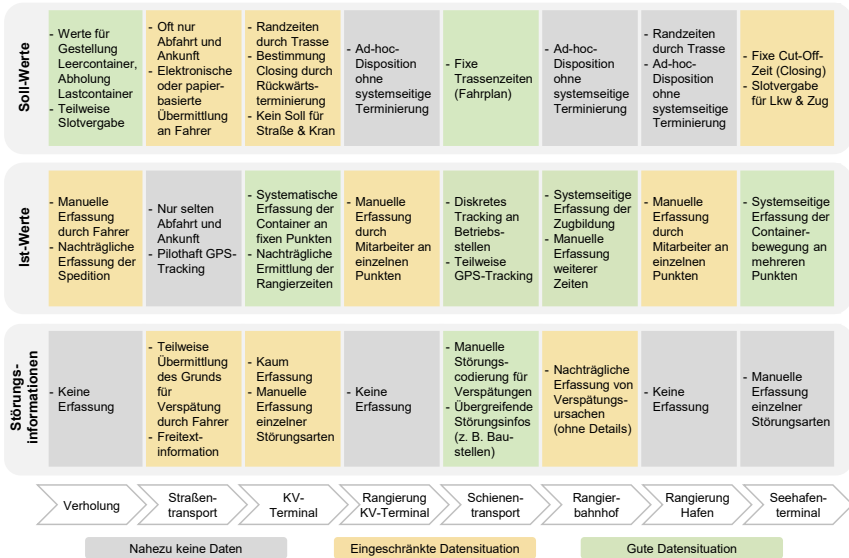


Abbildung 81: Data-Pre-Check im ETA-Anwendungsfall⁶⁹⁴

Zusammen mit den internen und externen Dateneigentümern werden die Beschaffungsmöglichkeiten dieser Daten für das ETA-Projekt grob bewertet. Hierzu werden den externen Instanzen bereits Möglichkeiten zur späteren Unterzeichnung von Geheimhaltungsvereinbarungen sowie die Exklusion geschäftsrelevanter Informationen, wie Auftragsbezeichnungen, in Aussicht gestellt. Zusammen mit der Möglichkeit zur Kompensation der datenseitigen White Spots durch eine geeignete Gestaltung der späteren Modeallarchitektur wird insgesamt festgestellt, dass die essenziell benötigten Daten für das Projekt voraussichtlich beschaffbar sind, wodurch die Kriterien des Quality Gates M2 erfüllt sind.

M3 – Auswahlentscheidung: Unter Einbeziehung der identifizierten Stakeholder, wozu auch die späteren Nutzer zählen, werden im nächsten Schritt die Anforderungen an die ML-Anwendung und an deren Umfeld sowie die mit der Einführung der Anwendung verbundenen Potenziale und Risiken erhoben. Die in diesem Zusammenhang aufgenommenen Meinungsbilder werden unter Moderation der Projektleitung in einheitliche Ziele überführt. Dies betrifft zunächst den späteren Einsatzbereich der Anwendung, der sich über die Transportplanung und -steuerung für den Export von Containern hinaus auf weitere Transportketten für andere Güter und Inbound-Prozesse sowie auf weitere Geschäftsprozesse, wie z. B. die Personalplanung, erstreckt. In Bezug auf die technischen Ziele beinhaltet dies u. a. die primären Funktionalitäten

⁶⁹⁴ Eine Darstellung in Anlehnung an Straube et al. (2020a), S. 31

der Anwendung, welche neben der ETA-Prognose noch eine diesbezügliche Ausgabe von geeigneten Aktionen zur Transportplanung und -steuerung umfassen sollen, sowie die systemtechnische Ausprägung, welche eine spätere Integration des Systems als Service auf einer modularen Plattform des Unternehmens vorsieht. Ferner werden die benötigten Bezugspunkte und -objekte der Prognose, deren genauer Inhalt sowie die angestrebte Ergebnisqualität festgelegt, wobei Letzteres sowohl für die gesamte Prozesskette als auch für die verschiedenen Bezugspunkte erfolgt. Für die mit dem Einsatz der ML-Anwendung intendierten Auswirkungen werden prozessuale Ziele für die zukünftige Entscheidungsausführung, z. B. eine Reduzierung der manuellen Tätigkeiten und der Entscheidungszeit, sowie betriebswirtschaftlichen Ziele, z. B. eine Reduzierung von Sondertransporten und Leerfahrten, fixiert.

Während sich diese Festlegungen auf den systemseitigen Zielzustand beziehen, erfolgt für ausgewählte Ziele eine Anpassung in Bezug auf die einzelnen Entwicklungsstufen der Anwendung im Sinne eines Skalierungskonzeptes. Hinsichtlich des Einsatzbereiches wird für die Realisierung der Prototypen in Form des PoC und MVP eine Beschränkung auf den Pilotanwendungsfall des kombinierten Straße-Schiene-Transportes und drei damit verbundenen Pilotrelationen vorgenommen. Diese stellen u. a. aufgrund des jeweiligen Güteraufkommens, der Auslastung der involvierten KV-Terminals sowie der Datenverfügbarkeit repräsentative Ausschnitte des Transportnetzwerkes dar. Auch ist für die Entwicklungsstufe des PoC eine geringe Zuverlässigkeit der Ergebnisse zulässig. Zusätzlich soll für die Prototypenstufen eine visuelle Benutzerschnittstelle zu Demonstrations- und Validierungszwecken umgesetzt werden. Die Ziele werden mit zentralen Erkenntnissen aus der Analyse- und Konzeptionsphase, u. a. in Form der infizierten Defizite bei der Entscheidungsausführung und der voraussichtlichen Datenverfügbarkeit für das Projekt, in einem Anwendungssteckbrief zusammengefasst (siehe Abbildung 82). Dieser dient der Unternehmensführung als Grundlage für die Entscheidung zur Umsetzung der Anwendung im Sinne des Quality Gates M3.

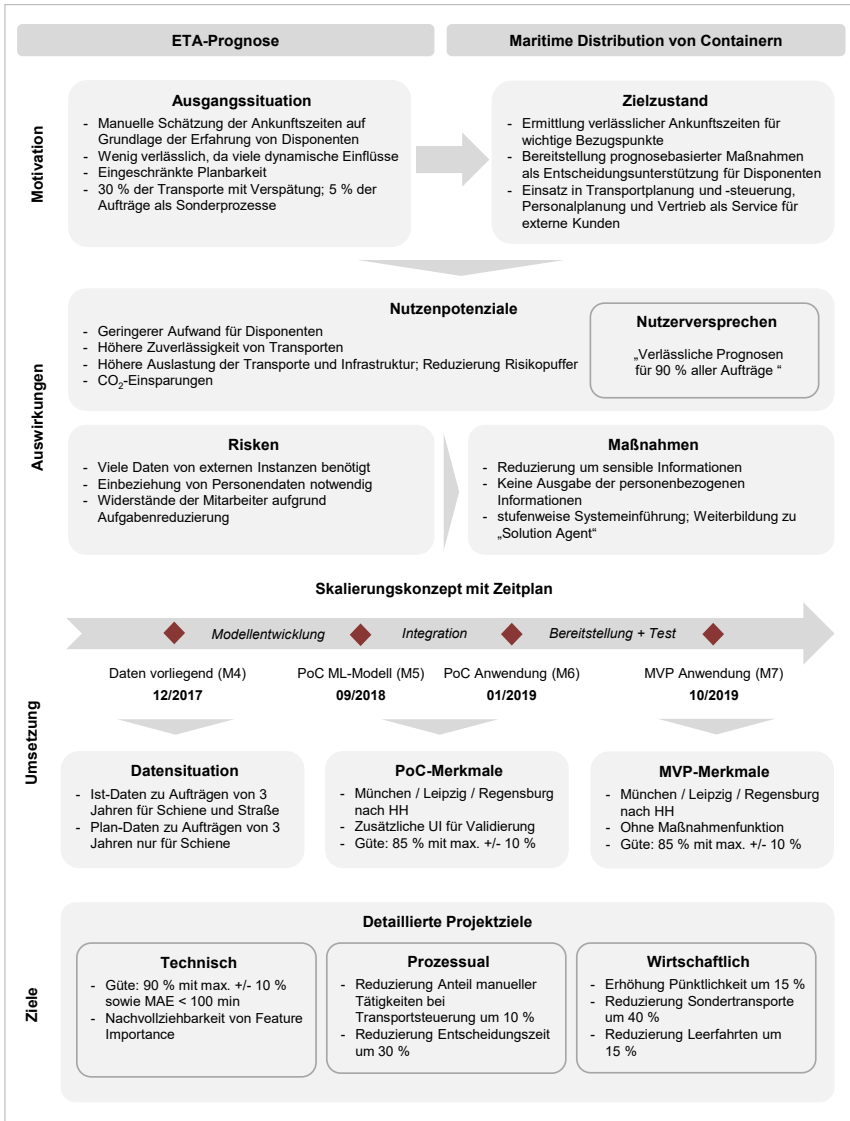


Abbildung 82: Anwendungssteckbrief im ETA-Anwendungsfall⁶⁹⁵

M4 – Prüfung der Datenbasis: Im nächsten Schritt werden die für den Pilotanwendungsfall benötigten und gleichzeitig verfügbaren Daten im ETA-Projekt beschafft und analysiert, sodass die indikative Einschätzung aus dem Data-Pre-Check zur datenseitigen Realisierbarkeit

⁶⁹⁵ Eine Darstellung

der Anwendung plausibilisiert werden kann. Hierzu wird einleitend der Datenbedarf für eine idealtypische Gestaltung der Anwendung auf Grundlage von weiterem gewonnenen Wissen zu den Prozessen und den damit verbundenen Einflussfaktoren konkretisiert. Hinsichtlich der benötigten Datenarten wird erkannt, dass neben den Ist-Informationen zum Transportverlauf auch Zusatzinformationen zur Verbindung der einzelnen Prozesse benötigt werden, da sich die jeweiligen Daten auf unterschiedliche Bezugsobjekte, wie Lkw und Züge sowie einzelne Wagen und Container, beziehen. Die Konkretisierung der Datenqualität sieht u. a. einen Bedarf von historischen Daten für drei Jahre vor, welche in Rohform und im Falle der Bewegungsdaten in einer Frequenz von mindestens 15 Minuten vorliegen sollten. Ausgehend von diesem idealtypischen Szenario werden datenseitige Minimalanforderungen abgeleitet, die eine Verfügbarkeit von Ist-Informationen für die Start- und Ankunftszeit der beiden Prozesse des Straßen- und Schienentransportes für zwei Jahre umfassen.

Gemeinsam mit den Prozessverantwortlichen und IT-Architekten wird die Suche nach verfügbaren Daten für das Projekt inner- und außerhalb des Unternehmens intensiviert, was zu einer Konkretisierung der Erkenntnisse des Pre-Checks führt. Die fehlende Datenabdeckung für die Rangierprozesse wird hierbei bestätigt. Zusätzlich wird erkannt, dass die verfügbaren Daten für den Prozess der Containergestellung nicht ausreichend sind. Auch muss festgestellt werden, dass eine Einbindung von Daten zu den Seehafenterminals für das Projekt nicht möglich ist. Die einzelnen Daten werden beschafft und aufbereitet, was auch deren Integration mittels eindeutiger Schlüsselvariablen umfasst, wodurch eine datenseitige Abbildung von Transportaufträgen entlang der Prozesskette möglich wird. Unter Durchführung verschiedener Datenanalysen wird die Qualität der Daten bewertet, was u. a. zur Aufdeckung von fehlenden Informationen und von Widersprüchen führt, welche teilweise auf eine manuelle Dateneingabe zurückzuführen sind. Die Erkenntnisse aus der Datenbeschaffung und -analyse werden dokumentiert und mit den definierten Minimalanforderungen verglichen (siehe Abbildung 83). Trotz der Einschränkungen für einzelne Prozesse ist eine ausreichende Datenbasis für die angestrebte Anwendung gegeben, sodass die Kriterien des Quality Gates M4 erfüllt sind und in die Entwicklung der einzelnen technischen Komponenten übergegangen wird.

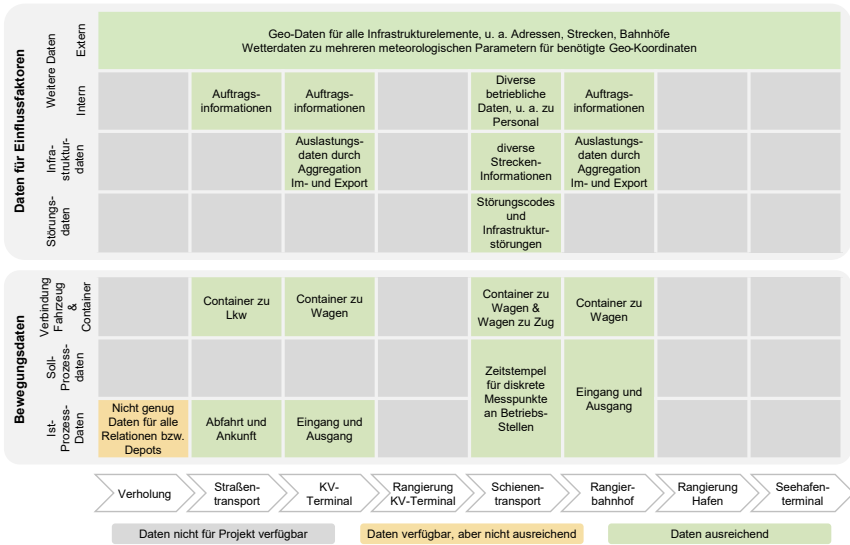


Abbildung 83: Bewertung der vorhandenen Datenbasis im ETA-Anwendungsfall⁶⁹⁶

M5 – Test der ML-Modelle unter Offline-Bedingungen: Anschließend erfolgt die Entwicklung der ML-Modelle für die ETA-Prognose, wobei durch die Gewinnung neuer Erkenntnisse auch weiterhin datenseitige Aktivitäten, wie die Beschaffung, Aufbereitung und Analyse der Daten, notwendig sind. Auf Grundlage der Informationen zu den betrieblichen und datenseitigen Rahmenbedingungen des Anwendungsfalls sowie zu den damit verbundenen prozessualen Unterschieden wird zu Beginn das Gesamtprognoseproblem in Form der Door-to-Port-ETA in mehrere Teilprobleme zerlegt, die durch separate Teilmodelle repräsentiert sind. Zur Ermittlung einer optimalen Gestaltung der Modellarchitektur und der einzelnen Teilmodelle werden mehrere Ansätze getestet, wozu auch der Einsatz verschiedener Lernverfahren mit unterschiedlichen Parametereinstellungen gehört. Die gemäß der Zielsetzung angestrebte Ergebnisqualität für die ETA wird mittels einer Segmentierung in sechs prozessspezifische Prognoseprobleme erreicht, die u. a. eine Exklusion des Prozesses der Verholung und des Umschlags im Seehafen sowie eine Integration der Rangierprozesse in das Teilmodell der Schienentransporte vorsehen. Die angestrebte Gesamtprognose setzt sich bei der gewählten Architektur aus einer logischen Verknüpfung der Teilmodelle im Sinne einer Prozesskettenprognose zusammen, bei der die Modelle sukzessive aufeinander aufbauen. Insgesamt erweisen sich Ensemble-Learning-Verfahren in Form von Random Forest, Gradient Boosting und Linear Regression Trees als geeignetste Lernverfahren für die einzelnen Regressions- um Klassifikationsprobleme, was u. a. im Zusammenhang mit ihrer Fähigkeit zum Umgang mit einer hohen Anzahl von Merkmalen steht.

⁶⁹⁶ Eine Darstellung in Anlehnung an Straube et al. (2020a), S. 43

Obgleich die technischen Ziele bereits mit dem identifizierten Lösungsansatz erreicht sind, werden im Rahmen der Entwicklung auch mehrere Defizite und darauf basierende Verbesserungsmöglichkeiten der Modelle ermittelt. Dazu zählt prozessübergreifend eine stärkere Einbindung von Daten zu technischen Störungen an der Infrastruktur und am jeweils genutzten Fahrzeug sowie zu verkehrsbedingten Einflussfaktoren, die bisher nicht ausreichend berücksichtigt sind. Selbiges gilt für große Störungsereignisse, die selten auftreten, aber eine hohe zeitliche Auswirkung haben, wie Stürme oder Streiks. Die gewonnenen Erkenntnisse zur Gestaltung der ML-Modelle für den Anwendungsfall werden in Form eines Modellsteckbriefes dokumentiert (siehe Abbildung 84), der die Entscheidungsgrundlage für die Bewertung des Quality Gates M5 bildet.




Abbildung 84: Modellsteckbrief im ETA-Anwendungsfall⁶⁹⁷

M6 – Test der ML-Anwendung unter Offline-Bedingungen: Die entwickelten ML-Modelle für die Door-to-Port-Prognose werden zusammen mit den weiteren technischen Komponenten, die zur Realisierung der Funktionen des angestrebten Systems benötigt und parallel zu den Modellen entwickelt wurden, in eine übergreifende Anwendung überführt. Entsprechend eines übergeordneten Funktionsprinzips (siehe Abbildung 85) werden die Prognosemodelle mit einer Komponente zur Erkennung von Abweichungen vom geplanten Prozessablauf systemseitig verbunden. Eine weitere Komponente, die als wissensbasiertes System umgesetzt

⁶⁹⁷ Eine Darstellung in Anlehnung an Straube et al. (2020a), S. 59, 61

wurde, generiert auf Basis detektierter Abweichungen geeignete Aktionen für die Transportplanung und -steuerung. Zusätzlich ist eine Komponente für die automatische Qualitätsbewertung der Ergebnisse vorgesehen, bei der u. a. ein Abgleich mit den tatsächlich realisierten Zeiten stattfindet. Gemäß des Skalierungskonzeptes wird für die prototypischen Entwicklungsstufen zudem eine Komponente zur visuellen Darstellung der Ergebnisse integriert. Neben der Ausgabe der ETA für die einzelnen Bezugspunkte und der ermittelten Aktionen beinhaltet das auch Zusatzinformationen zur Ergebnisqualität, einschließlich von Warnhinweisen. Die Visualisierung dient der Bewertung des systemseitigen Reifegrades und erhöht gleichzeitig das Verständnis bei den Nutzern für die Anwendung. Mit der erfolgreichen Testung des Funktionsprinzips unter Offline-Bedingungen sind die Kriterien des Quality Gates M6 erfüllt.

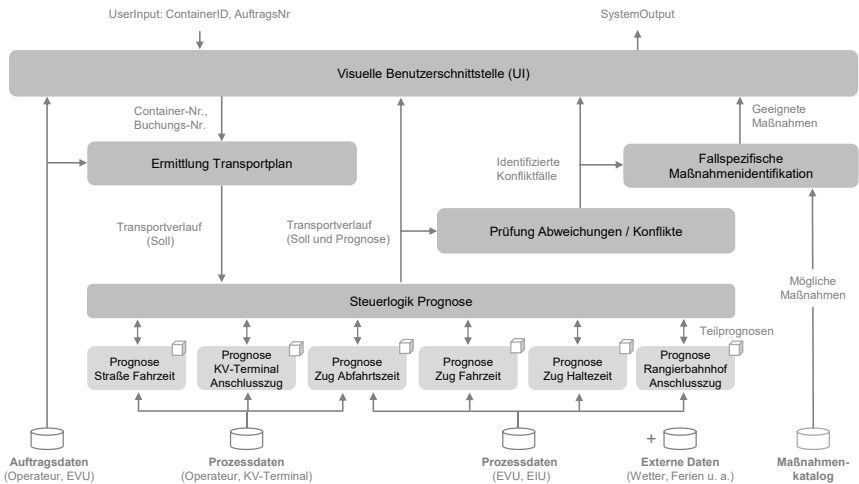


Abbildung 85: Funktionsprinzip des PoC für Anwendung im ETA-Anwendungsfall⁶⁹⁸

M7 – Test der ML-Anwendung unter Online-Bedingungen: Der realisierte PoC der Anwendung wird mit einem reduzierten Funktionsumfang, welcher zuvorderst die Realisierung der ETA-Prognose umfasst, in die produktive Zielumgebung überführt. Dazu wird die benötigte IT-Infrastruktur zur Ausführung der Anwendungen und zum Datenaustausch eingerichtet, was auch die Programmierung von noch nicht berücksichtigten Schnittstellen für die Input-Daten und für die Weitergabe des Outputs an die Zielsysteme umfasst.

Die bisherige Daten-Pipeline zur Aufbereitung der Input-Daten wird im Sinne einer Trainings-Pipeline erweitert, welche auf Basis von neuen Daten eine systemseitige Aktualisierung der Prognosemodelle durch eine Automatisierung des gesamten Prozesses der Modellanpassung ermöglicht. Für das automatische Re-Training wird ein Zeitplan festgelegt, der eine allnächtliche Aktualisierung vorsieht. Ferner wird die Komponente zur Qualitätsbewertung um Kontroll-

⁶⁹⁸ Eine Darstellung in Anlehnung an Straube et al. (2020a), S. 105

und Steuerungsmechanismen ergänzt, die zu einer ereignisbasierten Anpassung der Modelle im Falle einer strukturellen Abweichung der Prognosegüte führen. Die realisierte Anwendung wird im Live-Betrieb gemäß aller definierten technischen Zielgrößen über drei Monate getestet, wodurch systemseitige Stärken und Schwächen erkannt werden, auf deren Grundlage eine Verbesserung der ML-Modelle vorgenommen wird. Dies beinhaltet ein iteratives Durchlaufen der einzelnen Entwicklungsschritte sowie der Anpassung der Trainings-Pipeline. Mit der Erreichung der technischen Ziele ist die Funktionsfähigkeit der reduzierten Anwendung unter Online-Bedingungen sichergestellt und damit das Quality Gate M7 erreicht.

M8 – Prüfung der Auswirkungen der ML-Anwendung: In Ergänzung zur vorausgegangenen technischen Überprüfung wird die ETA-Anwendung auch hinsichtlich der festgelegten prozessualen und betriebswirtschaftlichen Ziele überprüft. Zur Sicherstellung einer kontinuierlichen Zielerreichung wird dazu ein längerer Testzeitraum von vier Monaten vorgenommen. Die Überprüfung der einzelnen Zielgrößen erfolgt zum Teil manuell, u. a. in Form einer Messung der Prozesszeit zur Disposition für neue Aufträge unter Nutzung der systemseitig generierten ETA-Informationen. Die Reduzierung von induzierten Verspätungen und von durchgeführten Sondertransporten wird im Rahmen bestehender Leistungsindikatoren erfasst. Die kostenseitigen Einsparungen werden durch die im Business Case genutzten Berechnungslogiken ermittelt. Neben der Erfassung dieser zielgebundenen Auswirkungen werden auch die Nutzer zu ihrer subjektiven Wahrnehmung befragt, um sowohl Anpassung an der Anwendung vorzunehmen als auch Qualifizierungsmaßnahmen für die Mitarbeiter einzuleiten. Mit der permanenten Sicherstellung der intendierten prozessualen und betriebswirtschaftlichen Auswirkungen sind die Kriterien des Quality Gates M8 erfüllt.

M9 – Test der skalierten ML-Anwendung: Die bisher ausschließlich für den Pilotanwendungsfall und die drei Relationen umgesetzte prototypische Anwendung, deren produktive Überführung sich außerdem auf die Funktionalität der ETA-Prognose beschränkte, wird nun entsprechend dem festgelegten Skalierungskonzept erweitert. Dies umfasst zum einen die prozessuale Erweiterung hinsichtlich weiterer Relationen für die maritime Distribution, aber auch die Übertragung auf Inbound-Transporte und auf ungebrochene Straßentransporte. Entsprechend der damit einhergehenden Veränderungen der prozessualen und datenseitigen Anforderungen werden größere Anpassungen an den bestehenden Modellen vorgenommen, was wiederum ein iteratives Durchlaufen der Schritte zur Entwicklung und betrieblichen Einführung beinhaltet. Zum anderen findet auch eine funktionale Erweiterung der Anwendung um die bereits im Rahmen des PoC integrierte Funktion zur Ausgabe von geeigneten Aktionen für die Transportplanung und -steuerung statt, die bei der Realisierung des MVP unberücksichtigt blieb und nun ebenfalls unter Live-Bedingungen für das erweiterte prozessuale Spektrum eingesetzt wird. Nach erfolgreicher Testung der skalierten Anwendung im Sinne der Kriterien des Quality Gates M9 ist die Anwendung zur ETA-Prognose ohne Einschränkungen im Unternehmen und für die intendierte Bereitstellung als externer Service einsatzfähig.

Nach Prüfung dieses HF anhand des ETA-Anwendungsfalls lässt sich eine Operationalisierung aller wesentlichen Aktivitäten feststellen. Dies bezieht sich sowohl auf die einzelnen Schritte des Vorgehens als auch auf die formulierten Quality Gates, welche inhaltlich und strukturell für die Auswahl und Umsetzung der betrachteten ML-Anwendung geeignet sind. Die fallspezifischen Ausprägungen führen zu einer Erfüllung von acht Anforderungen (siehe Tabelle 24).

Anforderung	Erfüllung im Anwendungsfall durch Maßnahmen des HF
Standardprozesse	Die Strukturierung anhand von Quality Gates, deren Erreichung an fixierte Kriterien geknüpft ist, stellt ein systematisches Vorgehen bei der Auswahl und Umsetzung der ML-Anwendung sicher.
Zuverlässigkeit	Das agile Vorgehen, welches eine Iteration der einzelnen Entwicklungsschritte zulässt, motiviert die Testung verschiedener Lösungsansätze. In Verbindung mit den Quality Gates führt das zu einem „systematischen Experimentieren“ bei der Entwicklung.
Systemdenken	Von Beginn an wird das Gesamtsystem in Form der angestrebten ML-Anwendung betrachtet und auch die Definition der Ziele dahingehend ausgerichtet.
Komplexitätsbeherrschung	Die Reduktion der angestrebten ML-Anwendung auf mehrere Entwicklungsstufen ermöglicht eine Fokussierung auf ausgewählte Funktionen und Prozesse, die bei Erreichung der jeweiligen Ziele gemäß der Quality Gates inkrementell erweitert werden.
Business Case	Bei der Auswahlentscheidung werden festgelegte betriebswirtschaftliche Ziele der ML-Anwendung berücksichtigt. Deren Erreichung wird im Rahmen eines Quality Gates umfassend überprüft.
Skalierbarkeit	Die frühzeitige Erstellung eines Skalierungskonzeptes, welches eine spätere prozessuale und funktionale Erweiterung der ML-Anwendung und eine Erhebung der damit verbundenen Anforderungen vorsieht, wirkt Insellösungen entgegen.
Interdisziplinäre Kooperation	Das Vorgehen sieht in den einzelnen Schritten eine intensive Einbindung verschiedener und wechselnder Wissensträger – auch außerhalb des IT-Bereiches – vor, einschließlich von Vertretern aus der Nutzergruppe.
Transparenz	Der Anwendungssteckbrief zeigt für die Stakeholder alle wesentlichen Informationen zur Anwendung auf, einschließlich der Potenziale und Risiken.

Tabelle 24: Handlungsfeld Ablauforganisation – Erfüllung der Anforderungen

7.4 Aufbauorganisation: Agile Strukturen für ML-Projekte mit zentraler Koordination

Das Ziel der Maßnahmen dieses HF ist die Realisierung von Organisationsstrukturen, die ein agiles Vorgehen bei der Umsetzung von ML-Anwendungen ermöglichen und gleichzeitig die Konformität der Aktivitäten zu den festgelegten strategischen Zielen gewährleisten. Die operative Verantwortung über den Umsetzungsprozess ist autonom agierenden, produktorientierten Projektteams zu übertragen, welche sich aus Personen mit unterschiedlichen Kompetenzprofilen zusammensetzen. Die ML-Projekte sind organisatorisch an den jeweiligen IT-Funktionsbereich der Unternehmen anzugliedern, wobei diese Bereiche zur Sicherstellung der be-

notigten Flexibilität, Interdisziplinarität und Vernetzung der Projektteams in agile Organisationseinheiten zu überführen sind. Diese Skalierung der agilen Prinzipien (siehe HF Ablauforganisation) ist in Anlehnung an das Spotify-Modell vorzunehmen. Parallel zu diesen dezentralen Strukturen ist eine zentrale Kontrollinstanz in Form eines Digital Transformation Office (DTO) zu bilden, welche projektübergreifend die ML-Aktivitäten verantwortet und in Hinblick auf die strategische Planung überwacht und steuert. Eine Zusammenfassung der Maßnahmen mit dem zugrundeliegenden Handlungsbedarf findet sich in Abbildung 86.



Abbildung 86: Handlungsfield Aufbauorganisation – Übersicht⁶⁹⁹

7.4.1 Bildung interdisziplinärer ML-Projektteams

Entsprechend der technischen Neuartigkeit für viele Unternehmen handelt es sich bei der Umsetzung von ML-Anwendungen um komplexe Vorhaben mit einer hohen Individualität. Vor diesem Hintergrund sind die damit verbundenen Aktivitäten innerhalb temporär zu bildender Organisationseinheiten in Form von **Projekten** auszuführen. Für die Zusammensetzung der Teams von ML-Projekten werden Mitarbeiter mit unterschiedlichen Kompetenzen benötigt. Im

⁶⁹⁹ Eigene Darstellung

Rahmen der vorliegenden Untersuchung konnten hierfür mehrere Kompetenzprofile identifiziert werden, die von den Unternehmen als **projektübergreifende Rollen** bei der Umsetzung von ML-Anwendungen bereitzustellen und in Tabelle 25 mit ihren wesentlichen Aufgaben aufgeführt sind.

Rolle	Funktion
Leitung Gesamtsystem	Verantwortung der Umsetzung des Gesamtsystems, inkl. ML-Modelle und anderer technischer Komponenten; Koordination der Stakeholder
Leitung Modellentwicklung	Verantwortung der Umsetzung der ML-Modelle; Koordination der Stakeholder
Business Analyst	Aufnahme und IT-bezogene Spezifikation von betrieblichen Anforderungen; Erstellung von Wirtschaftlichkeitsanalysen
Datenwissenschaftler	Implementierung der ML-Modelle, einschließlich Konzeption, Erstellung und Training; Interpretation von Datenmustern
Dateningenieur	Aufbereitung und Integration von Daten, einschließlich der Implementierung von Pipelines; Einrichtung der IT-Infrastruktur
Datenanalyst	Erstellung von Datenanalysen und diesbezüglichen Visualisierungen
IT-Architekt	Identifikation relevanter IT-Systeme und Daten im Unternehmen; Zugang zu Systemen
Dateneigentümer	Bereitstellung und Erklärung von Daten
Domänenexperten, inkl. Prozessverantwortliche	Anforderungsformulierung; Bereitstellung von Wissen zu Prozessen und Daten; Validierung und Testung; Entwicklung eines Systemverständnisses
Arbeitnehmervertretung	Anforderungsformulierung; Überwachung der Entwicklung und des Einsatzes
Nutzer	Anforderungsformulierung; Validierung und Testung

Tabelle 25: Rollen und deren Funktionen in ML-Projekten⁷⁰⁰

Entsprechend der dargestellten Rollen sind neben „klassischen“ IT-Entwicklern auch Fachkräfte mit Kompetenzen im Bereich der Entwicklung von ML-Modellen und der Aufbereitung und Analyse von Daten einzubinden. Auch werden spezialisierte Mitarbeiter für den Betrieb der Systeme benötigt, z. B. für die Integration in die Zielumgebung, für das Testen und für die Administration. Im Gegensatz zu konventionellen Softwaresystemen, bei denen häufig nach einer initialen Anforderungserhebung eine isolierte Entwicklung durch die IT erfolgt, bedarf es im Falle von ML-Anwendungen einer kontinuierlichen Einbindung von verschiedenen Mitarbeitern außerhalb des IT-Bereiches in Form von Wissensträgern zu den jeweiligen Prozessen und Daten. Demnach wird insbesondere für die experimentelle Ermittlung geeigneter Features und für die Bestimmung diesbezüglicher Daten, aber auch für die Konfiguration der ML-Modelle sowie derer Validierung und Verbesserung **während des gesamten Umsetzungsprozesses domänenspezifisches Wissen** benötigt. Dieses kann vorab nur indikativ eingeholt

⁷⁰⁰ Die dargestellten Rollen beziehen sich vorrangig auf die Umsetzung der ML-Modelle. In Abhängigkeit der Komplexität und des Entwicklungsstands des übergeordneten Gesamtsystems sind noch weitere klassische IT-Rollen in die Projekte einzubinden, z. B. Entwickler für das Front- und Backend sowie Administratoren. Auch bedarf es fallweise weiterer Rollen, wie z. B. Juristen.

werden, da der tatsächliche Informationsbedarf erst auf Basis von entwicklungsseitigen Erkenntnissen durch eine Verzahnung der prozessualen und technischen Perspektive entsteht.

Fester Bestandteil der Projektteams müssen auch Vertreter der späteren **Nutzergemeinschaft** sein, welche mit wechselnder Intensität von der Problemspezifikation und Konzeptionierung über die Entwicklung bis zum betrieblichen Einsatz der ML-Anwendungen einzubinden sind. Der User-Community-Ansatz (siehe HF Ablauforganisation) stellt eine konsequente Ausrichtung der Lösungsgestaltung auf die potenziellen Nutzer bzw. auf deren Probleme bei der Ausführung der Entscheidungsprozesse sicher. Zur Abdeckung eines möglichst breiten Anforderungsspektrums für eine maximale Skalierung der Anwendungen sind dabei potenzielle Nutzer zu verschiedenen Anwendungsfällen zu berücksichtigen. Die Nutzer sollen neue Erkenntnisse aus fachlicher Sicht validieren sowie die Anwendungen hinsichtlich ihres Nutzens und der Bedienbarkeit testen. Neben einer darauf basierenden Verbesserung der Lösungsgestaltung wird dadurch auch das Verständnis über das Systemverhalten bei dieser Personengruppe erhöht, was sich positiv auf die Akzeptanz auswirkt und die Grundlage für die spätere Nutzung darstellt. Als übergeordnete Repräsentanten der Nutzergemeinschaft sind zudem Mitarbeiter einer etwaig bestehenden Arbeitnehmervertretung, z. B. in Form des **Betriebsrates**, durchgehend in die ML-Projekte einzubinden. Weiterhin werden Personen mit ausgeprägten (Projekt-) **Managementkompetenzen** zur Organisation und Führung der Vorhaben sowie der Koordination verschiedener Interessengruppen benötigt. Die Leitung der Projekte kann in Abhängigkeit der Komplexität der angestrebten Anwendung entweder in Personalunion durch eine Person oder getrennt durch zwei Personen, welche in einer Linienbeziehung zueinander stehen und die Umsetzung der ML-Modelle bzw. des Gesamtsystems verantworten, erfolgen. Von einer Übertragung der Gesamtprojektleitung auf einen Data Scientist ist dabei abzusehen, da diese tendenziell zur Premature Optimization neigen.

Der tatsächliche Kompetenz- und Personalbedarf zur Abdeckung der einzelnen Rollen ist projektabhängig zu ermitteln. Fallweise können mehrere Rollen durch einen Mitarbeiter mit entsprechender Qualifikation abgedeckt werden, v. a. bei kleineren Anwendungen. Auch **variiert die Intensität der Einbindung** in Abhängigkeit der Projektphasen. Projektübergreifend lassen sich aber auch Rollen mit einem vergleichsweise hohen Arbeitsaufwand feststellen, wozu neben der Projektleitung der Data Scientist und Data Engineer gehören.

7.4.2 Skalierung agiler Prinzipien im IT-Bereich

Die einzelnen ML-Projekte sind organisatorisch im jeweiligen **IT-Funktionsbereich** der Unternehmen zu integrieren, wodurch gleichzeitig eine Bereitstellung der benötigten Ressourcen und eine Nähe zu den adressierten Problemen gewährleistet wird. Hierzu sind die IT-Bereiche – welche gegenwärtig zumeist noch als klassische Problemlöser und weniger als Innovator agieren – in agile Organisationseinheiten zu überführen, sodass sie eine flexible Bildung von interdisziplinären Teams mit einer Entscheidungsautonomie sowie eine Vernetzung von Mitarbeitern ermöglichen. Für diese **Skalierung von agilen Prinzipien** auf größere Einheiten

existieren mehrere Möglichkeiten (Frameworks), die in der Praxis jeweils verschiedene Vor- und Nachteile aufweisen.⁷⁰¹ Die optimale Skalierung hängt von den individuellen Rahmenbedingungen der Organisationseinheiten ab, u. a. der Anzahl der betroffenen Mitarbeiter, der Eingliederung in den Wertschöpfungsprozess sowie der strategischen Ziele. Entsprechend der komplexen funktionalen Organisationsstrukturen wird im Falle der betrachteten Industrieunternehmen die Orientierung am **Spotify-Modell** empfohlen, da diese matrixartige Organisationsform keine gänzliche Neugestaltung bestehender Strukturen erfordert, sondern die Möglichkeit zur Vereinigung vorhandener Linienorganisationen mit agilen Elementen bietet⁷⁰². Das Spotify-Modell sieht vier verschiedene Arten von miteinander interagierenden Organisationseinheiten vor (siehe Abbildung 87), deren Ausgestaltung in Hinblick auf die Umsetzung von ML-Anwendungen zu adaptieren ist.




Abbildung 87: Agile Organisationsstruktur des IT-Bereiches mittels Spotify-Modell⁷⁰³

Auf unterster Ebene sind sog. **Squads** zu bilden, welche agile Projektteams zur Lösung eines spezifischen Problems darstellen. In Abhängigkeit der Komplexität des jeweils angestrebten Systems kann es sich hierbei um die Realisierung der gesamten ML-Anwendung oder lediglich um die Entwicklung der ML-Modelle handeln. Die Squads setzen sich aus den zuvor genannten Rollen von ML-Projekten zusammen, einschließlich eines Leiters in Form des sog. Product

⁷⁰¹ Vgl. Conboy, Carroll (2019), S. 45

⁷⁰² Namensgeber dieser Organisationform ist das schwedische IT-Unternehmen Spotify AB, für dessen Gesamtorganisation das Modell umgesetzt wurde. Vgl. Kniberg, Ivarsson (2012), S. 1

⁷⁰³ Eigene Darstellung mit Inhalten aus Kniberg, Ivarsson (2012), S. 1

Owner. Sie verantworten den vollständigen Umsetzungsprozess der ML-Anwendungen – beginnend mit der Sicherstellung der technischen Machbarkeit bis zu deren betrieblicher Einführung, d. h. von Quality Gate M2 bis M9 gemäß des Vorgehens in HF Ablauforganisation. Die Teams verfügen über ein eigenes Budget und können bei der Umsetzung **autonom agieren**. Dies betrifft auch einen flexiblen Wechsel von Mitarbeitern aus anderen Squads. Mehrere Squads, die Aufgaben für einen gemeinsamen Geschäftsprozess oder eine gemeinsame übergeordnete Zielstellung ausführen, sind in einem sog. **Tribe** zusammenzufassen. Die Führung dieser größeren Einheiten ist von sog. Tribe Leads zu übernehmen, welche direkt dem IT-Leiter, d. h. dem Chief Information Officer (CIO), unterstellt sind und ebenfalls produktorientiert – jedoch mit einer ausgeprägteren betriebswirtschaftlichen Perspektive – agieren.

Zur Sicherstellung des Informationsaustausches zwischen den Squads eines Tribes ist zusätzlich die Organisationseinheit der sog. **Chapter** vorzusehen, in denen Mitarbeiter mit der gleichen Funktion in fachlichen Netzwerken (sog. Communities) zusammengefasst werden. Dabei sind u. a. eigene Chapter für die ML-spezifischen Fachkräfte der einzelnen Squads, wie die Data Scientists, zu bilden, in denen die entsprechenden Personen auch nach Beendigung eines ML-Projektes oder einem Wechsel zwischen den Squads verbleiben. Diese ML- bzw. KI-Chapter sind von fachlich erfahrenen Mitarbeitern zu leiten, wobei – anders als bei der Linienorganisation – dieser sog. Chapter Lead nicht in die Arbeit der Squads eingreift, sondern seine Führung auf die Sicherstellung des Austauschs und der Weiterentwicklung der Mitarbeiter sowie auf die Etablierung von methodischen Standards beschränkt. Hierdurch wird trotz der Produktorientierung der Squads und Tribes ein Austausch von Erkenntnissen über Projekt- bzw. Anwendungsgrenzen hinweg ermöglicht. Zur Stärkung der Mitarbeiterkreativität und damit der Innovationskraft der Unternehmen sind neben dem formalisierten Austausch auch Anreize zu einer zusätzlichen informellen Vernetzung der Mitarbeiter zu schaffen, indem Möglichkeiten zur flexiblen Gründung sog. **Guilds** geboten werden. In diesen freiwilligen Netzwerken können sich Mitarbeiter mit gleichen Interessen über Tribe-Grenzen engagieren, was u. a. der Identifikation neuer ML-Anwendungsfälle und der Entwicklung alternativer Lösungskonzepte für bestehende Anwendungen dient. Diese flexiblen Kooperationsmöglichkeiten von Mitarbeitern in einer parallelen netzwerkartigen Organisationsstruktur zur Steigerung der Innovationsfähigkeit werden auch als **duales Betriebssystem** (Dual Operating Model) bezeichnet.⁷⁰⁴

7.4.3 Zentrale Koordination mittels Digital Transformation Office

Neben der Realisierung dezentraler Organisations- und Entscheidungsstrukturen auf Ebene der ML-Projekte und des verantwortenden IT-Bereiches bedarf es einer zusätzlichen Organisationseinheit, welche den Einsatz von ML im Sinne der strategischen Planung (siehe HF Strategie) übergreifend verantwortet, überwacht und steuert. Entsprechend des notwendigen Veränderungsprozesses von Organisationen, der sich in der Umsetzung von ML und weiteren

⁷⁰⁴ Vgl. Kotter (2014), S. 20 f.

digitalen Technologien begründet, wird die Bildung eines **Digital Transformation Office** empfohlen, welches neben den ML-Aktivitäten auch weitere Aufgaben zur digitalen Transformation der Unternehmen orchestriert. Aufgrund der strategischen Bedeutung ist diese Organisationseinheit als **Stabsstelle** entweder an den CIO (Chief Information Officer) bzw. an die Geschäftsführung anzugliedern (siehe Abbildung 87). Die daraus resultierende Verbindung von dezentralen und zentralen Elementen stellt einen zweckmäßigen Kompromiss für die komplexen Organisationsstrukturen von Industrieunternehmen dar, welche einer vollständigen agilen Restrukturierung der jeweiligen Gesamtorganisation gegenüberstehen.

In der **Rolle als unternehmensinterner Inkubator** stellt das DTO die langfristige Integration von ML in den Unternehmen sicher. Hierzu verantworten dessen Mitarbeiter die Identifikation geeigneter Anwendungsfälle für das Unternehmen (siehe HF Strategie), wofür kontinuierlich Ideen aus den Fachbereichen aufzunehmen sowie relevante interne und externe Trends zu beobachten sind. Gemeinsam mit anderen Stakeholdern prüft das DTO anschließend die strategische Eignung potenzieller ML-Anwendungen und initiiert deren Projektierung. Dabei verantwortet das Team ebenfalls die ersten Schritte des Umsetzungsprozesses bis zur Sicherstellung der technischen Machbarkeit im Rahmen des Quality Gates M2, bei dem eine Übergabe der Führung an das jeweilige ML-Projektteam in Form der Squads stattfindet. Neben dieser partiellen Mitwirkung bei der Umsetzung von Anwendungen kontrolliert und steuert das DTO die festgelegten Maßnahmen der strategischen Planung. Dies umfasst eine Fortschrittskontrolle, eine projektübergreifende Identifizierung von Synergien, eine Harmonisierung der Aktivitäten und eine Unterstützung bei Problemen, z. B. bei der Gewinnung von Mitarbeitern aus anderen Fachbereichen und von externen Instanzen für die Mitwirkung an den ML-Projekten. Unabhängig von konkreten Anwendungen fungiert diese Einheit zudem als **interner Berater** für Fragstellungen zu ML bzw. zur digitalen Transformation allgemein und initiiert in diesem Zusammenhang auch Maßnahmen zur Weiterbildung der Mitarbeiter (siehe HF Kompetenzmanagement).

7.4.4 Validierung

Die Umsetzung des ETA-Anwendungsfalls erfolgt innerhalb des IT-Bereiches, welcher zuvor – ausgehend von einer funktionalen Strukturierung – in eine agile Organisationsform transformiert wurde. Dazu wurden mehrere Tribes als größere Organisationseinheiten gebildet, von denen ein Tribe die Realisierung der zuvor beschriebenen Vision zur Realisierung einer autonomen Transportplanung und -steuerung verantwortet. Diesem Tribe unterstehen mehrere Squads, die jeweils ein System gemäß der strategischen Planung umsetzen, wozu auch die ETA-Anwendung gehört. Dieses „**ETA-Squad**“ verantwortet den gesamten Umsetzungsprozess der ML-Anwendung – von der Spezifizierung der Informationen aus der strategischen Planung bis hin zur Entwicklung eines einsatzfähigen Systems – und trifft in diesem Rahmen eigene Entscheidungen zur Gestaltung des Lösungsweges. Dazu setzt sich das Squad aus

Mitarbeitern mit unterschiedlichen Qualifikationsprofilen und aus verschiedenen Fachbereichen zusammen. Neben Spezialisten für die Entwicklung und den Betrieb der ML-Modelle sowie der weiteren technischen Komponenten handelt es sich um Vertreter aus den logistischen Fachbereichen, wozu im ETA-Anwendungsfall v. a. Transportplaner und Disponenten für die Gesamtkette und die einzelnen Teilprozesse gehören, welche notwendiges Prozesswissen und gleichzeitig die nutzerseitigen Anforderungen in die Systemgestaltung einbringen. Um neben den Partikularinteressen einzelner Teammitglieder auch die Bedarfe der gesamten Nutzergemeinschaft abzubilden, werden zusätzlich Mitglieder des Betriebsrates eingebunden. Analog zu der fortbestehenden Zugehörigkeit der Logistikvertreter zu ihren Fachbereichen sind auch die IT-seitigen Mitarbeiter weiterhin funktional organisiert. Demnach gehören z. B. die Data Scientists des ETA-Squads zusammen mit ML-Spezialisten aus anderen Squads zusätzlich einem **KI-Chapter** an, wodurch ein fachlicher Austausch zwischen den Projekten zum Erreichen der übergeordneten Tribe-Zielstellung sichergestellt wird. Gleichzeitig findet ein informeller Austausch mit Mitarbeitern aus anderen Tribes und Chapters in Rahmen von Guilds statt, in denen u. a. alternative Lernverfahren zur Realisierung der ETA-Prognose diskutiert werden können.

Der Fortschritt der ML-Anwendung für die ETA-Prognose wird fachlich durch die IT-Bereichsleitung kontrolliert. Auf übergeordneter Ebene findet zudem eine Überwachung durch das DTO statt, welches als Steuerungs- und Beratungsinstanz fungiert und in dieser Funktion u. a. die Einhaltung der strategischen Ziele prüft und größere Budgetanpassungen freigibt. Auch werden hierdurch Personen abseits der IT für die Mitarbeit in den Squads nominiert und Kontakte zu Instanzen außerhalb des Unternehmens aufgebaut, die für die Realisierung der ETA benötigt werden, z. B. Terminalbetreiber.

Nach Prüfung dieses HF anhand des ETA-Anwendungsfalls lässt sich eine Operationalisierung aller wesentlichen Aktivitäten sowie eine Erfüllung von sechs Anforderungen feststellen (siehe Tabelle 26).

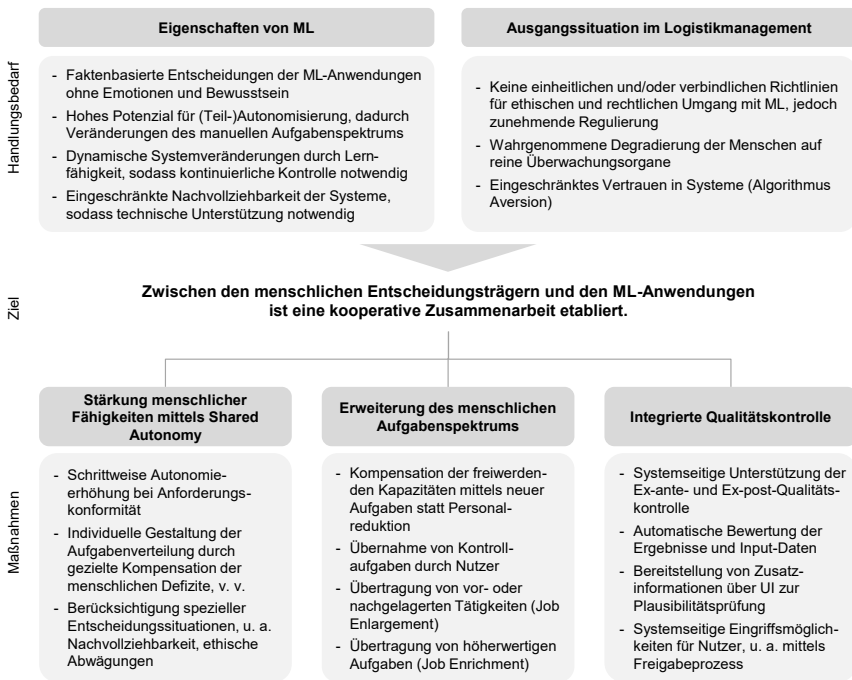
Anforderung	Erfüllung im Anwendungsfall durch Maßnahmen des HF
Interdisziplinäre Kooperation	Das Spotify-Modell ermöglicht eine flexible Einbindung verschiedener Mitarbeiter aus dem IT-Bereich in das ML-Projekt und unterstützt dadurch den DevOps-Ansatz. Zudem können über das DTO Vertreter aus anderen Bereichen nominiert werden.
Akzeptanz	Im Sinne des User-Community-Ansatzes werden von Beginn an die späteren Nutzer in den Umsetzungsprozess miteinbezogen, was deren Verständnis zur ML-Anwendung erhöht und die diesbezügliche Einstellung verbessert.
Compliance	Vertreter des Betriebsrates sind von Beginn an Teil des Projektteams. Sie stellen die Wahrung der Interessen und der datenseitigen Sicherheitsbedürfnisse von Arbeitnehmern bei der Gestaltung und beim Einsatz der ML-Anwendung sicher.
Systemdenken	Das Projektteam verantwortet die Umsetzung der gesamten Anwendung, einschließlich aller Komponenten. Durch die Zusammenfassung der ML-Fachkräfte in Chapters wird ein projektübergreifender Erfahrungsaustausch sichergestellt, der mittels der Guilds zusätzlich um eine informelle Vernetzung ergänzt ist.

Zuverlässigkeit	Mit der agilen Organisationsstruktur wird dem Projektteam die Möglichkeit zur Testung verschiedener Lösungsansätze gegeben und eine offene Fehlerkultur etabliert.
Personal und Finanzen	Durch die Zusammenfassung der ML-Fachkräfte innerhalb eines eigenen Chapters kann das Projekt flexibel auf die Ressourcen mit den benötigten Qualifikationsprofilen zurückgreifen.
Strategic Fit	Durch das DTO findet eine initiale und kontinuierliche Überprüfung der ML-Anwendung hinsichtlich der strategischen Ziele statt.

Tabelle 26: Handlungsfeld Aufbauorganisation – Erfüllung der Anforderungen

7.5 Mensch-Computer-Interaktion: Einsatz kollaborierender Systeme

Das Ziel der Maßnahmen dieses HF ist die Etablierung einer kooperativen Zusammenarbeit zwischen den menschlichen Entscheidungsträgern und den ML-Anwendungen, bei der die Stärken beider Akteure gezielt kombiniert werden. Dazu ist eine arbeitsorganisatorische Verteilung der Aufgaben bzw. Entscheidungsumfänge vorzunehmen, die sich nach den jeweiligen Anforderungen der Anwendungsfälle richtet. Die daraus resultierende Anpassung des ursprünglichen Aufgabenspektrums der Entscheidungsträger betrifft die notwendige Kontrolle der Systeme während des gesamten Betriebs. Zur Unterstützung dieser Tätigkeiten sind die ML-Anwendungen mit den Funktionen einer automatischen Qualitätsbewertung der Ergebnisse und einer Ausgabe damit verbundener Zusatzinformationen über eine Benutzerschnittstelle auszustatten. Neben der Aufnahme der Kontrollaktivitäten ist auch eine gezielte Erweiterung des Aufgabenspektrums der Entscheidungsträger in Form angrenzender und/oder höherwertiger Aufgaben mit einem größeren Verantwortungsbereich vorzunehmen, was auch eine Anpassung ihres Rollenverständnisses notwendig macht. Eine Zusammenfassung der Maßnahmen mit dem zugrundeliegenden Handlungsbedarf findet sich in Abbildung 88.

Abbildung 88: Handlungsfeld Mensch-Computer-Interaktion – Übersicht⁷⁰⁵

7.5.1 Stärkung menschlicher Fähigkeiten mittels Shared Autonomy

Gemäß den Ausführungen in Kapitel 6.2.3 lässt sich die Verteilung von Aufgaben bei der Ausführung von Entscheidungsprozessen zwischen den ML-Anwendungen und Menschen in verschiedene Stufen unterteilen, aus denen mehrere potenzielle Zusammenarbeitsformen resultieren. Diese reichen von einem assistierenden bis zu einem vollautonomen Einsatz der Systeme und haben große Auswirkungen auf das Aufgabenspektrum der menschlichen Entscheidungsträger (siehe Abbildung 89). Die Realisierung einer systemseitigen Autonomie ist dabei grundsätzlich **schrittweise durchzuführen**, da die systemseitigen Fähigkeiten erst im Rahmen eines längeren Betriebs final feststellbar sind. Ausgehend von einem assistierenden Einsatz ist demnach die Konformität aller systembezogenen Anforderungen, einschließlich der Akzeptanz der involvierten Mitarbeiter, sicherzustellen.

⁷⁰⁵ Eigene Darstellung




Abbildung 89: Aufgabenverteilung zwischen ML-Anwendungen und Menschen⁷⁰⁶

Ein für das Logistikmanagement empfohlenes Szenario zur Zusammenarbeit stellt die **partielle Autonomie** dar, welche gemäß den vorliegenden Untersuchungen von den meisten Logistikvertretern präferiert wird. Der Mensch übernimmt hierbei nur bestimmte Entscheidungen, wobei auch in diesen Fällen parallel eine Ergebnisbereitstellung und damit eine Unterstützung durch die Systeme erfolgt. Den restlichen Teil der Entscheidungen führen die Systeme eigenständig aus, wobei deren Ergebnisse vor der Ausführung, z. B. der Übergabe der Information an andere Systeme, durch den Menschen – ggf. unter Zuhilfenahme einer technischen Unterstützung – kontrolliert werden. Im Falle von nicht zufriedenstellenden systemseitigen Ergebnissen führt der Mensch diese Entscheidungen eigenständig aus. Dementsprechend verbleibt er auch in der Funktion als faktischer Entscheidungsträger; jedoch werden die damit verbundenen Umfänge reduziert. Die genaue Ausprägung ist dabei abhängig von der jeweiligen Aufteilung zwischen beiden Akteuren, welche für die Anwendungsfälle individuell festzulegen ist.

Grundsätzlich ist bei der Aufgabenaufteilung dem menschenzentrierten Leitbild (siehe HF Strategie) zu folgen, woraus sich ein gezielter Einsatz der ML-Anwendungen zur Stärkung der menschlichen Fähigkeiten ergibt. Dazu sind die menschlichen „Defizite“ bei der Ausführung von Entscheidungen (siehe Kapitel 2.3.4) durch systemseitige Stärken zu kompensieren, v. v. Dieser Ansatz der **kooperativen Zusammenarbeit** mit technischen Systemen wird auch als Shared Autonomy bezeichnet und entstammt dem Einsatz von kollaborierenden Robotern für die Unterstützung von ausführenden Tätigkeiten (sog. Cobots). Entsprechend ihrer höheren Leistungsfähigkeit bei der Informationsverarbeitung und -speicherung zeichnen sich ML-Anwendungen bei vielen Problemstellungen durch **bessere und schnellere Entscheidungen**

⁷⁰⁶ Eigene Darstellung

gegenüber den Menschen aus, sodass diese Umfänge tendenziell den Systemen zu übertragen sind. Gleichzeitig existieren aber weiterhin Entscheidungssituationen, in denen z. B. aufgrund von fehlenden Daten bzw. einer hohen Individualität die menschlichen Entscheidungen eine höhere Qualität aufweisen. Vor diesem Hintergrund bietet sich zwischen beiden Akteuren eine Aufteilung von Standard- und Sonderprozessen an, wobei erstere all jene Entscheidungssituationen umfassen, die zuverlässig durch die Systeme ausgeführt werden können.

Darüber hinaus sind bei der Aufgabenverteilung aber auch Problemstellungen zu berücksichtigen, die neben der Ergebniszuverlässigkeit weitere Anforderungen an Entscheidungen stellen. Dies umfasst bspw. **rechtliche Vorgaben** zur Nachvollziehbarkeit der Entscheidungsfindung, die von vielen ML-Anwendungen entsprechend des Black-Box-Charakters nicht gewährleistet werden können, sodass diese Entscheidungen weiterhin durch den Menschen auszuführen sind. Auch betrifft dies **ethische Abwägungen** bei der Entscheidungsfindung, die entsprechend dem fehlenden Bewusstsein von ML-Anwendungen exklusiv dem Menschen vorbehalten sind. Neben strategischen Entscheidungen mit hohen Auswirkungen auf die Wettbewerbsfähigkeit der Unternehmen gehören hierzu insbesondere Personalentscheidungen.

7.5.2 Erweiterung des menschlichen Aufgabenspektrums

Im Rahmen des Einsatzes von ML-Anwendungen reduzieren sich die ursprünglichen Aufgaben für die menschlichen Entscheidungsträger; gleichzeitig entstehen auch neue Aufgaben in Form der systemseitigen Kontrolle. Hierfür sind neue Fähigkeiten bei den Nutzern zu entwickeln, die eine Interpretation des Systemverhaltens und eine Detektion von kritischen Entscheidungssituation ermöglichen (siehe HF Kompetenzmanagement). In Abhängigkeit der genauen Aufgabenteilung kann diese Veränderung des Aufgabenspektrums dazu führen, dass die Mitarbeiter nur in Sonderfällen agieren müssen („**Exception Handler**“), was sich jedoch negativ auf deren Arbeitsmotivation und Problemlösungsfähigkeiten sowie damit langfristig auch auf die Innovationskraft der Unternehmen auswirkt (siehe Kapitel 5.4.3). Da in vielen Fällen die neu hinzukommenden Kontrollaufgaben die reduzierten Entscheidungsumfänge nicht überkompensieren werden, ist insgesamt von einer geringeren benötigten Arbeitszeit je Mitarbeiter auszugehen. Dies kann unternehmensseitig zur gezielten **Verringerung des Personalbedarfs** genutzt werden, indem die verbleibenden manuellen Tätigkeiten auf weniger Mitarbeiter verteilt werden, wodurch sich deren Arbeitsumfang wiederum vergrößert, z. B. durch die Übernahme weiterer Kunden oder Regionen. Diese isolierte betriebswirtschaftliche Sicht steht jedoch im Gegensatz zu dem formulierten menschenzentrierten Leitbild zum Einsatz von ML; ferner verhindert sie nicht die o. g. negativen Effekte für die restlichen Mitarbeiter.

Vor diesem Hintergrund wird anstelle eines umfassenden Abbaus von Arbeitsplätzen eine gezielte Erweiterung der Aufgaben der Mitarbeiter abseits ihrer bisherigen Tätigkeiten empfohlen. Die beiden damit verbundenen motivationstheoretischen Strategien führen zur Steigerung der Produktivität der Mitarbeiter und können damit langfristig einen höheren wirtschaftlichen

Effekt im Vergleich zur kurzfristigen Reduktion der Personalkosten für die Unternehmen erzielen (siehe Abbildung 90). Zum einen ist dazu eine horizontale Erweiterung (sog. **Job Enlargement**) vorzunehmen, indem die bisherigen Aufgaben von Mitarbeitern um vor- oder nachgelagerte Tätigkeiten ergänzt werden.⁷⁰⁷ Als Beispiel hierfür dient das Aufgabenspektrum eines Disponenten in der Beschaffung, welches bisher vordergründig eine Ermittlung geeigneter Bestellmengen und -zeitpunkte für Materialien vorsah. Durch die Übernahme bestimmter Materialgruppen durch eine ML-Anwendung, wie sie bspw. im Anwendungsfall 3 in Kapitel 4.3.3 umgesetzt wurde, kann dieser Disponent zusätzliche Aktivitäten zur Überwachung und Steuerung der entsprechenden Lieferanten ausführen. Zum anderen ist eine vertikale Erweiterung (sog. **Job Enrichment**) zu realisieren, welche die Übertragung von neuen, komplexeren Aufgaben auf die Mitarbeiter beinhaltet, wozu auch eine höhere Verantwortung und Entscheidungsautonomie zählen.⁷⁰⁸ Dies kann u. a. die Ausweitung des Planungshorizontes von operativen hin zu taktisch-strategischen Aufgaben umfassen, indem bspw. ein Fertigungssteuerer neben den bisherigen Dispositionsaufgaben für Produktionsaufträge, welche nun partiell von ML-Anwendungen ausgeführt werden, auch Aufgaben zur längerfristigen Produktionsplanung übernimmt. Auch ist eine Erweiterung des organisatorischen Betrachtungsbereiches möglich, indem bspw. anstelle einer bisherigen Verantwortung für einzelne Aufträge und Kunden durch einen Mitarbeiter in der Bestandsplanung nun ein gesamtes Programm oder Werk bis hin zu einem gesamten Standortverbund im Sinne einer Netzwerksteuerung verantwortet wird.




Abbildung 90: Veränderung des Aufgabenspektrums durch ML-Anwendungen⁷⁰⁹

Im Rahmen dieser horizontalen und vertikalen Erweiterung des Aufgabenspektrums erhöht sich auch der Betrachtungs- und Gestaltungsbereich der Mitarbeiter, sodass diese als sog. **Solution Agents** zur ganzheitlichen Bewertung und Lösung von komplexen Problemen eingesetzt werden können. Darüber hinaus sind sie stärker mit innovierenden und optimierenden Aufgaben zur Verbesserung von Produkten und Prozessen zu betrauen. Insgesamt führt die Entlastung bei den bisherigen Aufgaben, z. B. in Bezug auf die Ausführung von Standardprozessen, zu einer Übernahme von **Aufgaben mit einer höheren Wertigkeit** im Rahmen der

⁷⁰⁷ Vgl. Nerdinger et al. (2011), S. 356

⁷⁰⁸ Vgl. Nerdinger et al. (2011), S. 357

⁷⁰⁹ Eigene Darstellung

dadurch frei gewordenen Kapazitäten. Neben den funktionalen Vorteilen verbessert diese Veränderung das Selbstverständnis der Mitarbeiter, was einen zusätzlichen positiven Effekt auf die Motivation und damit auf die individuelle Leistung nimmt.

7.5.3 Integrierte Qualitätskontrolle

Im Rahmen des Einsatzes von ML-Anwendungen ist der menschliche Entscheidungsträger bzw. der Nutzer zur Kontrolle der systemseitigen Ergebnisse einzusetzen, um bei Problemen eingreifen zu können. Dies bezieht sich zum einen auf die systemseitige Entscheidungsfindung im Sinne einer **Ex-ante-Qualitätskontrolle**, wodurch eine Ausführung von fehlerhaften oder aus anderen Gründen ungeeigneten Entscheidungen, d. h. deren Realisierung in Form von Aktionen oder deren Übergabe an andere Systeme, verhindert wird (siehe Abbildung 91). Zum anderen sind die Ergebnisse auch nach ihrer Ausführung zu kontrollieren, was primär der Optimierung von ML-Anwendungen dient (siehe HF Ablauforganisation). Anders als bei den vorausgegangenen Kontrollaufgaben ist diese **Ex-post-Qualitätskontrolle** auch beim vollautonomen Einsatz von ML-Anwendungen durchzuführen. Zur Erzielung eines Verständnisses über das Systemverhalten sind hierbei zudem mehrere Fälle aggregiert zu betrachten.

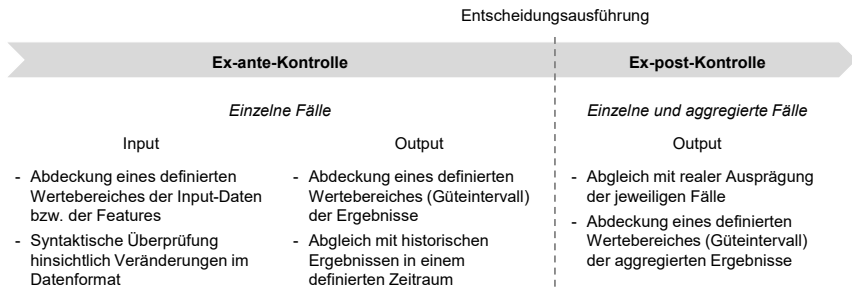


Abbildung 91: Maßnahmen zur Qualitätskontrolle von ML-Anwendungen⁷¹⁰

Im Gegensatz zu konventioneller Software kann sich das Verhalten von ML-Anwendungen durch die Aktualisierung der Datenbasis im Rahmen des Re-Trainings verändern (siehe Kapitel 6.3.3), sodass eine permanente Kontrolle der Systeme sicherzustellen ist. Infolge des damit verbundenen Aufwands, der durch die eingeschränkten Möglichkeiten zur Nachvollziehbarkeit der jeweiligen Lösungswege zusätzlich erhöht wird, sind systemseitige Voraussetzungen zur Unterstützung der menschlichen Entscheidungsträger bei den Ex-ante- und Ex-post-Kontrollaufgaben zu schaffen.

Dies betrifft zum einen die Befähigung der Systeme zur **selbstständigen Bewertung der Ergebnisse**, um dadurch automatisch Anomalien, aber auch grundsätzliche Auffälligkeiten und unsichere Ergebnisse detektieren zu können. Hierzu sind für die Ex-ante-Qualitätskontrolle geeignete Plausibilitätsregeln zu definieren, indem bspw. Güteintervalle mit Schwellwerten für

⁷¹⁰ Eigene Darstellung

die Ergebnisausprägung festgelegt werden oder ein Ergebnisvergleich mit anderen Problemen in einem definierten historischen Zeitraum stattfindet. Neben dem Output sind auch die eingehenden Daten bzw. die daraus resultierenden Features systemseitig zu bewerten. Dies betrifft sowohl eine inhaltliche Kontrolle, z. B. hinsichtlich der Abdeckung eines definierten Wertebereiches, als auch eine syntaktische Überprüfung im Sinne eines veränderten Formates. Für die Ex-post-Qualitätskontrolle ist ein Abgleich der Ergebnisse mit den tatsächlichen Ausprägungen aus den Realdaten vorzusehen. Auch ist regelmäßig eine Auswertung der Ergebnisse über einen definierten Zeitraum nach statistischen und betrieblich relevanten Leistungsmetriken vorzunehmen. Vor diesem Hintergrund sind die generierten Ergebnisse und die Testungen zu speichern.

Zum anderen sind den Nutzern zusätzliche **Informationen zu den systemseitigen Entscheidungen** durch die ML-Anwendungen über ein UI bereitzustellen, die zu einer Plausibilisierung der Ergebnisse sowie einer Ursachenanalyse für das Systemverhalten beitragen. Neben den Resultaten der automatischen Qualitätsbewertung, z. B. in Form detektierter Abweichungen, umfasst das einen Abgleich der Ergebnisse mit Entscheidungen in ähnlichen Situationen, eine Darstellung der Feature-Ausprägungen mit dem jeweiligen Einfluss sowie die jeweils berücksichtigten Trainingsfälle. Hierdurch können die Nutzer abnormale Entscheidungssituationen feststellen, die sie im Sinne eines „Sonderprozesses“ eigenständig ausführen müssen. Gleichzeitig können potenzielle Anomalien als korrekte Ergebnisse deklariert werden. Zur Ausgabe der entsprechenden Informationen ist bei der Entwicklung der Systeme eine bewusste Auswahl von geeigneten Lernverfahren zu treffen, z. B. entscheidungsbaum-basierte Verfahren für die Ausgabe der Feature Importance.

Neben der Darstellung dieser Informationen sind bei der Gestaltung der UI mehrere Interaktionskomponenten zu berücksichtigen, die **Eingriffe der Nutzer** in die Entscheidungen der Systeme ermöglichen. Dies betrifft im Rahmen der Ex-ante-Qualitätskontrolle eine Verhinderung der Ausführung der systemseitigen Ergebnisse in allen nicht vollständig autonomen Zusammenarbeitsformen. Hierzu ist ein standardisierter Freigabeprozess zur ergebnisbezogenen Bestätigung der Ergebnisse durch die Nutzer umzusetzen. Zudem sind auch Möglichkeiten zur Beeinflussung des zukünftigen Systemverhaltens durch die Nutzer vorzusehen, indem diese die systemseitigen Ergebnisse bewerten können, was mittels Rückkopplung u. a. zu einer automatischen Anpassung der Merkmalsgewichtungen führt.

7.5.4 Validierung

In Hinblick auf das mit der formulierten Vision verbundene Szenario der vollständigen Autonomie der Transportplanung und -steuerung wird die Zusammenarbeit zwischen den Menschen und der ML-Anwendung stufenweise im ETA-Anwendungsfall verändert. Zu Beginn ist das System als reine Entscheidungsunterstützung in die Prozesse eingebunden, sodass parallel zu den systemseitig berechneten ETA-Informationen eine Ermittlung durch den Menschen

stattfindet, bevor diese an die Dispositionssysteme weitergegeben werden. Nach einer Ver-
 stätigung der benötigten Ergebnisqualität im Rahmen eines längeren Testbetriebs wird für be-
 stimmte Entscheidungssituationen eine Übergabe der systemseitigen ETA-Informationen an
 die Zielsysteme zugelassen, wobei weiterhin eine Freigabe durch den Menschen erfolgen
 muss. Diese Sonderfälle, in denen die menschlichen Entscheidungsträger weiterhin die ETA
 berechnen, werden anhand der jeweiligen Feature-Ausprägungen detektiert und beziehen
 sich auf Situationen, in denen ein hohes Risiko systemseitiger Fehlentscheidungen besteht,
 z. B. beim Vorliegen von Stürmen.

Um sowohl ex ante abnormale Situationen als auch ex post fehlerhafte Entscheidungen der
 Systeme zielorientiert und mit einem geringen Aufwand zu detektieren, werden für die Bewer-
 tung des In- und Outputs der Systeme Plausibilitätsregeln implementiert, deren Ergebnisse für
 die Nutzer mittels einer visuellen UI dargestellt werden. Im Falle der Eingangsdaten umfasst
 dies Intervalle für die jeweiligen Feature-Ausprägungen, wie z. B. für die Windgeschwindigkei-
 ten, um das erwähnte Sturmzenario im Voraus zu erkennen. Für die systemseitigen Ergeb-
 nisse in Form der Prozesszeiten wird eine Ober- und Untergrenze festgelegt, nach der unreal-
 istisch geringe und hohe Ausprägungen zu Alarmmeldungen führen. Weiterhin werden die
 Ergebnisse um die Darstellung von Zusatzinformationen ergänzt. Dies umfasst eine Ausgabe
 der Bedeutung der einzelnen Features mit den entsprechenden Ausprägungen für jede Prognose,
 um Ursachen für Verspätungen detektieren zu können. Auch werden entwicklungssei-
 tige Informationen bereitgestellt, wie die Anzahl der einbezogenen Trainingsfälle je Teilmodell
 (siehe Abbildung 92). Zudem werden die ermittelten ETA ex post mit der tatsächlichen An-
 kunftszeit verglichen und die Abweichungen sowohl numerisch als auch grafisch dargestellt.

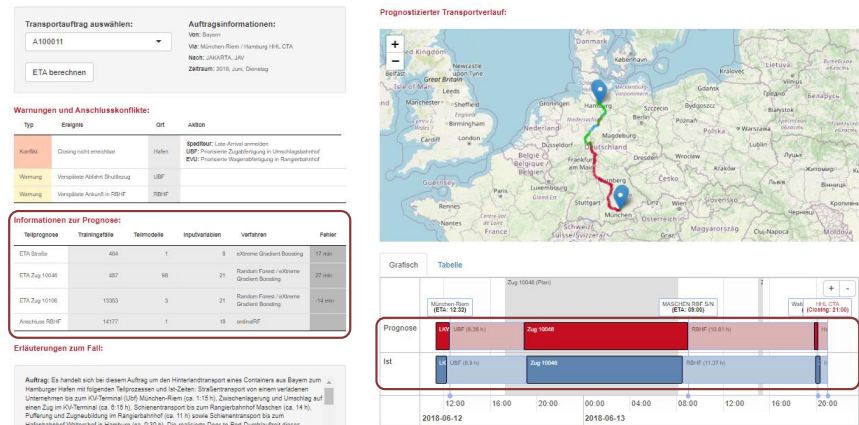


Abbildung 92: UI mit systemseitigen Zusatzinformationen im ETA-Anwendungsfall⁷¹¹

⁷¹¹ Es handelt sich um einen Screenshot der ETA-Anwendung. Die entwicklungsseitigen Zusatzinfor-
 mationen sind rot umrandet. Vgl. Technische Universität Berlin (2020)

Die durch den Einsatz der ML-Anwendung freigewordenen zeitlichen Kapazitäten der betroffenen Transportplaner und Disponenten werden im Sinne des formulierten Leitbildes nicht zum Abbau von Arbeitsplätzen genutzt. Stattdessen findet eine Erweiterung des Aufgabenspektrums auf andere, zum Teil höherwertige Aktivitäten statt. Demnach verantworten einige der Mitarbeiter nun eine deutlich größere Anzahl von Aufträgen, wodurch Synergien zwischen den diesbezüglichen Transporten erschlossen werden. Andere Mitarbeiter erweitern ihren Betrachtungsbereich um Inbound-Transporte für die Materialversorgung der eigenen Werke, wodurch die Transportkapazitäten besser ausgelastet werden können.

Nach Prüfung dieses HF anhand des ETA-Anwendungsfalls lässt sich eine Operationalisierung aller wesentlichen Aktivitäten sowie eine Erfüllung von vier Anforderungen feststellen (siehe Tabelle 27).

Anforderung	Erfüllung im Anwendungsfall durch Maßnahmen des HF
Akzeptanz	Die schrittweise Erhöhung der Autonomie der ML-Anwendung reduziert Widerstände bei den Mitarbeitern. Die gleichzeitige Hinzunahme höherwertiger Aufgaben führt zu einer Motivationssteigerung und verbessert die Wahrnehmung der Systeme.
Nachvollziehbarkeit	Das Verständnis über den Lösungsweg der ML-Anwendung wird durch die Ausgabe von systemseitigen Zusatzinformationen erhöht.
Kontrollierbarkeit des Lernprozesses	Die systemseitigen Zusatzinformationen ermöglichen einen zielorientierten Eingriff durch den Menschen. Dies kann zusätzlich mittels einer Bewertung der Ergebnisse vorgenommen werden, die zu einer direkten Rückkopplung an die Systeme führen.
Kontrollierbarkeit der Entscheidung	Die Weitergabe fehlerhafte Ergebnisse der Anwendung wird durch einen manuellen Freigabeprozess verhindert. Zudem findet eine systemseitige Unterstützung durch die Integration von Plausibilitätsregeln und die Ausgabe von Zusatzinformationen statt.

Tabelle 27: Handlungsfeld Mensch-Computer-Interaktion – Erfüllung der Anforderungen

7.6 Kompetenzmanagement: Mitarbeiter für Einsatz von ML sensibilisiert und befähigt

Das Ziel der Maßnahmen dieses HF ist die Sensibilisierung und Befähigung der Organisationsmitglieder zur Unterstützung des Einsatzes von ML-Anwendungen durch eine Vermittlung von individuellen Kompetenzen. Dies betrifft in erster Linie eine notwendige Qualifikation von Mitarbeitern und/oder deren externe Rekrutierung für die Entwicklung und den Betrieb entsprechender Systeme. Darüber hinaus ist auch bei allen anderen Mitarbeitern entlang der einzelnen Unternehmensebenen ein Grundverständnis zu ML auszubilden. Als gesonderte Zielgruppe ist zudem die designierte Nutzergemeinschaft der Systeme zu betrachten, deren Vertreter insbesondere zur Ausübung ihrer neuen Kontrollaufgaben zu befähigen sind. Neben der Vermittlung neuer Fertigkeiten und Kenntnisse zielen die Maßnahmen dieses HF auch auf eine Veränderung der Einstellung der Organisationsmitglieder und damit der gesamten Unternehmenskultur im Sinne eines Change Managements ab. Eine Zusammenfassung der Maßnahmen mit dem zugrundeliegenden Handlungsbedarf findet sich in Abbildung 93.

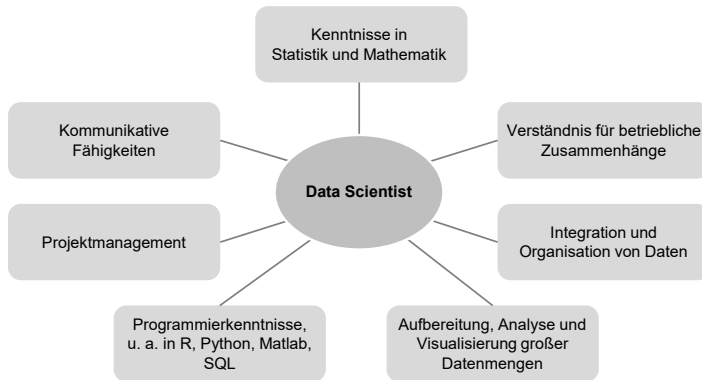


Abbildung 93: Handlungsfeld Kompetenzmanagement – Übersicht⁷¹²

7.6.1 Qualifizierung von Fachkräften ergänzt um externes Wissen

Für die Entwicklung und den Betrieb von ML-Anwendungen werden gemäß den Ausführungen zur Zusammensetzung von ML-Projekten im HF Aufbauorganisation mehrere Fachkräfte mit spezialisierten Kompetenzen benötigt – welche jedoch in vielen Unternehmen aktuell nicht vorhanden sind. Eine Schlüsselrolle nehmen hierbei **Data Scientists** ein, welche ein interdisziplinäres Qualifikationsprofil aufweisen müssen, das neben tendenziell IT-affinen Fähigkeiten zur Analyse und Aufbereitung großer Datenmengen sowie zur Entwicklung von ML-Modellen auch von einem Verständnis zu betrieblichen Zusammenhängen sowie von kommunikativen und organisatorischen Fähigkeiten zur Koordination der Projekte und der verschiedenen Stakeholder geprägt ist (siehe Abbildung 94).

⁷¹² Eigene Darstellung

Abbildung 94: Anforderungen an das Qualifikationsprofil von Data Scientists⁷¹³

Für die Gewinnung dieser ML-spezifischen Fachkräfte können in den Unternehmen **bestehende Mitarbeiter qualifiziert** werden, wofür insbesondere Personen mit ausgeprägten IT-Vorkenntnissen, aber auch Quereinsteiger mit einer betriebswirtschaftlichen Vorausbildung infrage kommen. Bei der Gestaltung der entsprechenden Weiterbildungsprogramme besteht die Möglichkeit eines Rückgriffs auf diverse Angebote von externen Dienstleistern und Hochschulen, welche von persönlichen und online-basierten Trainings bis zu vollständigen Studiengängen im Data-Science-Bereich reichen. Entsprechend der thematischen Komplexität ist diese Strategie der Personalgewinnung jedoch fallweise mit einem hohen zeitlichen Aufwand verbunden, sodass sich alternativ oder ergänzend eine **Rekrutierung von neuen Mitarbeitern** mit den entsprechenden Kompetenzen anbietet, womit die Time-to-Market für die angestrebten ML-Anwendungen verkürzt werden kann. Aufgrund des gegenwärtigen Mangels an entsprechenden Fachkräften auf dem nationalen und internationalen Arbeitsmarkt (siehe Kapitel 4.4.2) besteht jedoch bei dieser Strategie eine hohe Unsicherheit über die Abdeckung des Personalbedarfs der jeweiligen Unternehmen.

Zur Begegnung dieser personellen Herausforderungen besteht die Möglichkeit einer **Beauftragung externer Unternehmen** für die Unterstützung bei der Umsetzung von ML-Anwendungen. Neben der Übernahme einzelner Aufgaben, wie z. B. Datenanalysen, können die Leistungen auch eine vollständige Fremdvergabe der Anwendungsentwicklung umfassen. Als potenzielle Kooperationspartner existieren eine Vielzahl von spezialisierten Unternehmen, zu denen Start-ups, Beratungen und größere Technologieunternehmen zählen. Durch die Beauftragung kann der Zugang zu den angestrebten Systemen potenziell beschleunigt werden. Auch ergibt sich dadurch die Möglichkeit einer Partizipation an den unternehmens- und branchenübergreifenden Kenntnissen der Dienstleister. Im Rahmen der damit verbundenen **Build-or-Buy-Entscheidungen** sind jedoch auch potenziell negative Effekte zu berücksichtigen, die zusammenfassend in Tabelle 28 dargestellt sind. Demnach geht die Fremdvergabe mit einer

⁷¹³ Eigene Darstellung

Abhängigkeit von den Dienstleistern bei der Wartung und Skalierung der realisierten ML-Anwendungen einher. Auch wird nur eingeschränkt entwicklungsseitiges Wissen zu den jeweiligen Systemen sowie gesamthaft zu ML durch die auftraggebenden Unternehmen aufgebaut. Infolge der strategischen Bedeutung der Technologie für die Logistik wird daher nur für einzelne ML-Anwendungen oder diesbezügliche Teilaktivitäten eine Fremdvergabe empfohlen, welche zudem stets von einem eigenen Kompetenzaufbau zu begleiten ist. Einen zweckmäßigen Ansatz zur Kombination der Vorteile beider Realisierungsstrategien stellen Innovationspartnerschaften im Sinne einer **Open Innovation** dar, die mit den o. g. Dienstleistern, aber auch mit Wettbewerbern und Forschungseinrichtungen aufgebaut werden können.⁷¹⁴ Im Rahmen einer kooperativen Zusammenarbeit kann hierbei bspw. die fachliche Expertise der Unternehmen zu den Anwendungsfällen und zu den benötigten Daten mit den entwicklungsseitigen Kompetenzen der Partner zur gemeinsamen Lösungsgestaltung gebündelt werden.

	Eigenentwicklung (Build)	Fremdentwicklung (Buy)
Chancen	<ul style="list-style-type: none"> - Aufbau von Wissen bzw. Fachkräften zur Umsetzung, Wartung und Skalierung eigener Anwendungen sowie zur Bewertung externer Anwendungen - Stärkere Einflussmöglichkeiten auf die Gestaltung der Systeme - Organische Verankerung der Technologie, sodass höhere Akzeptanz zu erwarten ist 	<ul style="list-style-type: none"> - Partizipation an unternehmens- und branchenübergreifenden Kenntnissen, inkl. Trends - Kürzere Time-to-Market für Anwendungen - Variabilisierung von Kosten, sodass höhere Flexibilität und Risikominimierung im Falle eines Scheiterns
Risiken	<ul style="list-style-type: none"> - Spätere Realisierung der Anwendungen - Geringere Flexibilität durch Fixkosten (jedoch bei Verstetigung des Technologieeinsatzes hilfreich) 	<ul style="list-style-type: none"> - Kein eigener Wissensaufbau, sodass Abhängigkeit von Dienstleistern für Wartung und Skalierung der Anwendungen sowie eingeschränkte Bewertungsmöglichkeit - Einblick bzw. Bereitstellung von Daten und weiteren Informationen - Geringere Einflussmöglichkeiten auf Systemgestaltung

Tabelle 28: Bewertung der Eigen- oder Fremdentwicklung von ML-Anwendungen

Um entsprechend der Neuartigkeit und der forschungsseitigen Entwicklung von ML einen fachlichen Austausch zwischen den unternehmensinternen Fachkräften sowie deren kontinuierliche Weiterentwicklung zu ermöglichen, ist zudem die Bildung von ML-spezifischen **Communities** in den Unternehmen zu motivieren. Bei der Nutzung des im HF Ablauforganisation empfohlenen Spotify-Modells kann dies über den funktionalen Zusammenschluss in Chapters sowie mittels einer informellen Vernetzung in den Guilds sichergestellt werden.

7.6.2 Grundverständnis zu ML bei allen Organisationsmitgliedern

Über die an der Umsetzung von ML-Anwendungen beteiligten Personen hinaus ist bei allen weiteren Organisationsmitgliedern ein Grundverständnis zu ML sowie zum übergeordneten Bereich der KI zu entwickeln. Diese Maßnahme begründet sich einerseits mit der strategischen

⁷¹⁴ Vgl. Reipert (2019), S. 48 f.

Bedeutung der Technologie für die Unternehmen, nach der die Mitarbeiter zur direkten und indirekten Unterstützung zu befähigen sind, wozu die **Identifizierung von potenziell geeigneten Anwendungsfällen** und der bewusste Umgang mit den technischen Voraussetzungen der Anwendungen in Form von Daten gehören. Demnach müssen die Mitarbeiter ein **Verständnis für die Bedeutung von Daten** und für die damit verbundene Notwendigkeit einer hohen Qualität entwickeln. Diese gezielte Kompetenzerweiterung betrifft auch die Vertreter der Unternehmensführung, deren Technologieverständnis eine elementare Grundlage zur Realisierung des strategischen Potenzials von ML darstellt (siehe HF Strategie). Andererseits soll durch die Vermittlung von Wissen gezielt die **Einstellung der Mitarbeiter** gegenüber dem Einsatz von ML-Anwendungen beeinflusst werden. Grundlegend lassen sich anhand der aktuell vorherrschenden Einstellung drei relevante Gruppen von Unternehmensvertretern für solch eine gezielte Beeinflussung identifizieren:

- Mitarbeiter, denen ML bisher unbekannt ist, sodass eine indifferente Einstellung vorherrscht. Diese Mitarbeiter sind erstmalig für die Technologie zu sensibilisieren.
- Mitarbeiter, die eine eher negative Einstellung zu ML aufweisen, welche u. a. auf Ängste zum Verlust des eigenen Arbeitsplatzes und auf apokalyptische Visionen zurückgeht. Diesen Mitarbeiter sind die Vorurteile und Ängste zu nehmen.
- Mitarbeiter, bei denen sich eine positive Einstellung zu ML beobachten lässt, die jedoch von zu euphorischen Annahmen geprägt ist. Bei diesen Mitarbeitern ist eine realistische Erwartungshaltung zu entwickeln.

Unter Berücksichtigung der unterschiedlichen Einstellungen sind **zielgruppenspezifische Schulungen** für alle Organisationsmitglieder durchzuführen, welche die in Tabelle 29 dargestellten Lernziele und Inhalte umfassen sollten und in bestehende Weiterbildungsprogramme zu integrieren sind. Die Organisation und Moderation dieser Trainings sind durch das DTO zu verantworten (siehe HF Aufbauorganisation), wobei auch ein Rückgriff auf externe Dienstleister mit entsprechenden Kompetenzen erfolgen kann. Zur Veranschaulichung und Bekräftigung der Schulungsinhalte sind erfolgreich umgesetzte Anwendungen aus anderen Fachbereichen oder Unternehmen aufzuzeigen. Dies umfasst auch Verweise auf die bereits erfolgte Durchdringung von ML in alltäglichen Anwendungen und Geräten, z. B. in Form von Sprachassistenten, personalisierten Empfehlungen bei Online-Käufen oder Navigationsdiensten, wodurch der negativ besetzte Neuartigkeitscharakter der Technologie für die Mitarbeiter abgeschwächt wird. Zudem sind bei der Darstellung der Potenziale und Grenzen von ML-Anwendungen stets **Vergleiche zum Menschen** herzustellen. Hierdurch soll ein Bewusstsein für grundlegende Defizite und eine ergebnisbezogene Fehlbarkeit auf *beiden* Seiten erzeugt werden – mit dem Hinweis, dass die damit verbundene Wahrnehmung der Menschen jedoch häufig zu Lasten technischer Systeme ausfällt (Algorithmus-Aversion).

Lernziel für Mitarbeiter	Inhalt
ML ist ein wichtiger Bestandteil der notwendigen digitalen Transformation von Unternehmen.	Strategische Bedeutung der Digitalisierung für die Branche; Einordnung von ML in den KI-Technologieverbund; Beitrag zur digitalen Transformation
Mittels ML werden Systeme befähigt, auf Basis von Daten zu lernen.	Funktionsweise von ML; Ergebnisse sind nicht zufallsbasiert, sondern entstehen auf Grundlage mathematisch-statistischer Verfahren, realer Daten und manuell entwickelter Modelle („Entmystifizierung“ von ML)
Die Vorteile von ML betreffen alle Mitarbeiter direkt und indirekt.	Defizite von menschlichen Entscheidungsträgern; Potenziale von ML; Auswirkungen des Technologieeinsatzes auf Arbeitsumfeld der Mitarbeiter und auf langfristige Wettbewerbsfähigkeit der Unternehmen
Der Mensch ist trotz des Einsatzes von ML von hoher Bedeutung.	Aktuelle Fähigkeiten und Grenzen von ML; exklusive Fähigkeiten der Menschen; nicht absehbare Realisierung einer starken KI und Superintelligenz
Daten bestimmen die Ergebnisse der ML-Anwendungen.	Technische Voraussetzungen von ML; Datenqualität determiniert Ergebnisqualität („Garbage in, Garbage out“); Notwendigkeit einer korrekten Dateneingabe

Tabelle 29: Schulungsinhalte zu ML

Neben dieser Wissensvermittlung sind die Mitarbeiter auch mit existierenden ML-Anwendungen zu konfrontieren. Zu Beginn der Technologieeinführung kann dies durch Besuche bei anderen Unternehmen, Forschungseinrichtungen oder Technologielaboren für einzelne Personen realisiert werden. Nach dem Betrieb der ersten eigenen aussagekräftigen Systeme sind diese allen Organisationsmitgliedern als **Leuchtturminiativen** bekannt zu machen. Neben der unternehmensweiten Kommunikation von Informationen umfasst dies eine Realisierung von punktuellen oder kontinuierlichen Zugängen, z. B. mittels Veranstaltungen zur Vorstellung der Systeme oder durch deren „Ausstellung“ in Showrooms. Gleichzeitig können diese Anwendungen für die Außenkommunikation zur Verbesserung des Unternehmensimages genutzt werden. Auch bietet sich für ausgewählte Systeme eine **Personifizierung** an, indem diese als neue Mitarbeiter in Form „künstlich intelligenter“ Assistenten für die kooperative Zusammenarbeit mit den menschlichen Entscheidungsträgern bei kognitiv anspruchsvollen Aufgaben eingeführt werden. Diese Maßnahmen sind von einer Marketinginitiative zu begleiten, welche auch eine grafische Darstellung dieser neuen „Mitarbeiter“ und eine dazugehörige Change Story umfassen kann, wie sie am Beispiel der personifizierten Anwendung „alfred“ des Interviewpartners Thyssenkrupp Material Services in Abbildung 95 dargestellt ist.



ML-Anwendung „alfred“

- Benennung des Systems nach dem Firmengründer Alfred Krupp
- Grafische Darstellung für System
- Unterstützung des Nutzers bei komplexen Aufgaben, u. a. Materialdisposition im globalen Netzwerk
- Einsatz des Systems verbunden mit Change Story: Der Firmengründer wird als künstlicher Mitarbeiter wieder in das Unternehmen zurückgebracht.

Abbildung 95: Personifizierung von ML-Anwendungen – Praxisbeispiel⁷¹⁵


⁷¹⁵ Eigene Darstellung mit Inhalten aus Thyssenkrupp Materials Services (2019)

7.6.3 Nutzerseitige Interpretation des Systemverhaltens

Eine im Rahmen des Kompetenzmanagements separat zu betrachtende Zielgruppe stellt die Nutzergemeinschaft dar, welche aus den Entscheidungsträgern besteht, die mit ML-Anwendungen zusammenarbeiten. Neben ihrer grundsätzlich hohen Bedeutung für eine erfolgreiche Technologieadoption ergibt sich für diese Personen im Falle des Einsatzes von ML ein verändertes Aufgabenspektrum (siehe HF Mensch-Computer-Interaktion), wofür entsprechende Fähigkeiten auszubilden sind. Dies geht über Kenntnisse zu den systemseitigen Funktionen und Interaktionselementen hinaus, wie sie ebenfalls bei konventioneller Software notwendig sind. Vielmehr sind die betroffenen Mitarbeiter gezielt zur **Kontrolle der Systeme zu befähigen**, sodass sie das jeweilige Systemverhalten korrekt interpretieren können. In Bezug auf die Ex-ante-Kontrolle müssen die Mitarbeiter demnach unterschiedliche Entscheidungssituationen dahingehend bewerten können, ob den systemseitigen Ergebnissen vertraut werden kann oder ein manueller Eingriff notwendig ist. Im Falle der Aktivitäten der Ex-post-Kontrolle umfasst dies eine Detektion von systematischen Fehlentwicklungen der Anwendungen und eine Bestimmung von möglichen Ursachen.

Für die Ausbildung dieser Fähigkeiten ist den Mitarbeitern ein grundlegendes **Verständnis zur technischen Funktionsweise** der jeweiligen Anwendungen sowie gesamthaft zu ML zu vermitteln. Dazu gehört eine Kenntnis der jeweils verwendeten Input-Daten und der darauf basierenden wesentlichen Features, um das Verhalten der Systeme mit den ursächlichen Faktoren für die Entscheidungen sowie diesbezügliche Fähigkeiten und Grenzen verstehen zu können. Auch sind die Mitarbeiter für eine Interpretation der verwendeten Leistungsmetriken und für darüberhinausgehende systemseitig dargestellte Zusatzinformationen zur Plausibilisierung der Ergebnisse anzuleiten.

Die Vermittlung des benötigten Wissens ist – analog zu dem zuvor dargestellten Schulungsformat für alle Organisationsmitglieder – in Rahmen einzelner Veranstaltungen vorzunehmen. Die Schulungen sind dabei entweder unterstützend oder exklusiv **von bestehenden Nutzern durchzuführen**, welche im Rahmen des User-Community-Ansatzes in den Entwicklungsprozess und die betriebliche Einführung der jeweiligen Anwendungen eingebunden waren (siehe HF Ablauforganisation) und hierbei Erfahrungen zum Systemverhalten im Sinne eines „On-the-Job-Trainings“ gesammelt haben (siehe Abbildung 96). Die erzielten Erkenntnisse sind im Rahmen der Schulungen an andere Nutzer und weitere Organisationsmitglieder weiterzugeben. Entsprechend ihrer Zugehörigkeit zur Nutzergemeinschaft erhöht der Einsatz dieser ausgewählten Personen als Trainer die Glaubhaftigkeit der vermittelten Informationen, wodurch zusätzliches Vertrauen gegenüber den ML-Anwendungen geschaffen wird. Anders als bei konventioneller Software, zu der das systemseitige Wissen der Nutzer lediglich im Falle von entwicklungsseitigen Updates anzupassen ist, ergibt sich bei ML-Anwendungen ein kontinuierlicher Bedarf. Dies begründet sich mit möglichen Verhaltensänderungen der Systeme infolge deren Lernfähigkeit, weshalb ein **regelmäßiger Austausch der Nutzer** zu Erfahrungen aus dem Betrieb sicherzustellen ist.

Abbildung 96: User-Community-Ansatz zur Schulung der Nutzer⁷¹⁶

7.6.4 Validierung

Das betrachtete Unternehmen im ETA-Anwendungsfall rekrutiert mehrere Data Scientists und Data Engineers für die Umsetzung von ML-Anwendungen. Parallel werden bestehende Mitarbeiter aus der IT durch Weiterbildungsprogramme zum Aufbau von Kompetenzen in der Entwicklung von ML-Modellen qualifiziert. Im Falle der betrachteten ETA-Anwendungen wird zusätzlich für einen Zugang zu spezialisiertem Wissen eine Kooperation mit einem Forschungsinstitut eingegangen, welches Vorerfahrungen bei der Umsetzung von ML-basierten Prognosesystemen aufweist. Im Rahmen dieses partizipativen **Open-Innovation-Ansatzes** erfolgt eine gemeinsame Entwicklung der Anwendung. Auf eine Fremdvergabe wird aufgrund der Bedeutung und Komplexität der angestrebten Anwendung sowie der erwarteten notwendigen Anpassungen im Rahmen des Betriebs verzichtet.

Für die restlichen Organisationsmitglieder werden zielgruppendifferenzierte Schulungen für die Vermittlung von Wissen zu ML und zum übergeordneten Themenfeld der KI durchgeführt, welche auch die Darstellung von Voraussetzungen für geeignete ML-Anwendungsfälle beinhalten. In diesem Kontext werden auch erfolgreiche Anwendungsbeispiele aus anderen Unternehmen sowie aus dem privaten Alltag aufgeführt, die Parallelen zur angestrebten ETA-Prognose aufweisen, z. B. in Form von Navigationsdiensten. Entsprechend der hohen vermuteten Potenziale für die interne Optimierung und die Verwendung als externer Service wird die Umsetzung der ETA-Prognose als **Leuchtturminitiative** im Unternehmen „vermarktet“, was mit einer Kommunikation über verschiedene Kanäle einhergeht. Zusätzlich wird die Einführung mit einer Change Story verbunden, nach der die Mitarbeiter nun die Möglichkeit haben, „verlässlich in die Zukunft zu schauen“.

Über die Vermittlung des allgemeinen Technologiewissens hinaus werden die designierten Nutzer zusätzlich in der Zusammenarbeit mit der ETA-Anwendung geschult. Die umfasst deren Befähigung zur **Interpretation des Systemverhaltens**, indem sie u. a. Situationen detektieren können, die tendenziell zu unzuverlässigen Ergebnissen der Systeme führen. Dies gilt bspw. für Fälle von schweren Unwettern, bei denen die Mitarbeiter vermittelt bekommen, dass

⁷¹⁶ Eigene Darstellung

hierzu nur unzureichend Trainingsdaten vorhanden sind. Die Weitergabe dieses Wissens erfolgt durch ausgewählte Mitarbeiter, welche als Repräsentanten der Nutzergemeinschaft in den gesamten Umsetzungsprozess der Anwendungen eingebunden waren.

Nach Prüfung dieses HF anhand des ETA-Anwendungsfalls lässt sich eine Operationalisierung aller wesentlichen Aktivitäten sowie eine Erfüllung von sechs Anforderungen feststellen (siehe Tabelle 30).

Anforderung	Erfüllung im Anwendungsfall durch Maßnahmen des HF
Personal und Finanzen	Die Weiterbildung bestehender sowie die Rekrutierung neuer Mitarbeiter führt zu der Ausbildung eigener Fachkräfte für die Umsetzung der ML-Anwendung.
Kompetenz	Aufgrund der Durchführungen von Schulungen zum Themenfeld KI und ML wird bei allen Organisationsmitgliedern ein grundlegendes Technologieverständnis aufgebaut.
Standardprozesse	Die Vermittlung von Voraussetzungen für ML-Anwendungen befähigt alle Mitarbeiter zur Identifikation potenziell geeigneter Anwendungsfälle.
Akzeptanz	Durch die in den Schulungen vermittelte Bedeutung und Funktionsweise von ML mit dem Verweis auf menschliche Fehlbarkeit wird die Einstellung der Mitarbeiter gegenüber ML verbessert und der Algorithmus-Aversion entgegengewirkt.
Datenqualität	Die Vermittlung der Voraussetzungen von ML-Anwendungen führt zu einer Verbesserung des Bewusstseins bei den Mitarbeitern im Umgang mit Daten, u. a. in Bezug auf die manuelle Eingabe und deren Überprüfung.
Zuverlässigkeit	Durch den Verständnissgewinn zum Verhalten der Systeme werden die Nutzer zur Identifikation von Verbesserungsmöglichkeiten befähigt.

Tabelle 30: Handlungsfeld Kompetenzmanagement – Erfüllung der Anforderungen

7.7 Datenmanagement: Skalierbare ML-Services auf Basis konsolidierter Daten

Das Ziel der Maßnahmen dieses HF ist die Realisierung der infrastrukturellen Grundlagen zur effizienten Bereitstellung der benötigten Daten für die Entwicklung und den Betrieb von ML-Anwendungen sowie zu deren skalierbaren Einsatz in den Unternehmen. In einem ersten Schritt sind dazu die Daten aus den einzelnen IT-Systemen der Unternehmen gemeinsam mit relevanten und zugänglichen externen Daten in ihrer originären Struktur in einem Data Lake zentral zu speichern. Aus diesem Repository sind anschließend diejenigen Daten zusammenzuführen und aufzubereiten, die der aktuellen und historischen Zustandsbeschreibung von bedeutenden logistischen Bezugssystemen der Unternehmen dienen, sodass vollständige digitale Abbilder entstehen, deren Aufbereitungslogiken und Daten von ML-Anwendungen genutzt werden können. Die einzelnen Modelle dieser Digital Twins, der jeweiligen ML-Anwendungen und aller weiteren datenbasierten Anwendungen sind in einem zentralen IT-System in Form einer Plattform zu integrieren, auf der sie unternehmensintern und ggf. -extern als Services

bereitgestellt werden sowie als technische Grundlage für die Realisierung weiterer Systeme im Sinne eines „Inkubators“ fungieren können. Eine Zusammenfassung der Maßnahmen mit dem zugrundeliegenden Handlungsbedarf findet sich in Abbildung 97.



Abbildung 97: Handlungsfeld Datenmanagement – Übersicht⁷¹⁷

7.7.1 Systemagnostische Datenintegration mittels Data Lakes

Für die effiziente Bereitstellung von potenziell geeigneten Daten für ML-Anwendungsfälle im Logistikmanagement sind in den Unternehmen Data Lakes zu realisieren. Im Sinne einer „Single Source of Truth“ sollen diese zentralen Repository relevante Daten – sowohl in aktueller Form als auch für einen historischen Zeitraum – als Duplikate speichern, was auch eine regelmäßige Aktualisierung der bestehenden Datensätze sowie eine Erweiterung um neue Datenquellen impliziert. Hierfür sind die Data Lakes mit geeigneten APIs entsprechend gängiger unternehmensinterner und -übergreifender Standards auszustatten, sodass eine **systemagnostische Vernetzung** mit den einzelnen Quellsystemen gewährleistet wird.

Mit dem Ziel einer anwendungsübergreifenden und unternehmensweiten Nutzung der jeweiligen Data Lakes sind die Daten – anders als bei einem Data Warehouse oder häufig auch bei

⁷¹⁷ Eigene Darstellung

konventionellen Datenbanksystemen – **in Rohform zu speichern**. Lediglich kleinere Anpassungen im Falle von syntaktischen Defekten, z. B. bei uneinheitlichen Formaten, sind bei der Integration der Daten aus den Quellsystemen vorzunehmen. Zur Verwaltung der einzelnen Datensätze sind zudem relevante Hintergrundinformationen zu hinterlegen, z. B. Eigenschaften zu den jeweiligen Datenquellen sowie zur Datenqualität. Auch sind dabei inhaltliche Beziehungen zwischen den Daten herzustellen, wobei auf etwaige Redundanzen und Widersprüche hinzuweisen ist. Für die damit verbundenen Eingriffe sowie für eine gezielte Auswahl der benötigten Daten ist eine Benutzerschnittstelle zu den Data Lakes zu implementieren, mit der die Datenbestände durchsucht und zusätzlich durch vorgefertigte Auswertungsmöglichkeiten analysiert und visualisiert werden können.

Entsprechend des o. g. skalierbaren Einsatzes der Data Lakes ist eine Integration von **möglichst vielen Datenquellen** der jeweiligen Unternehmen zu verfolgen. In Hinblick auf potenzielle ML-Anwendungsfälle im Logistikmanagement betrifft dies zum einen Daten aus den ausführenden Prozessen, die teilweise direkt als Sensorinformationen von Maschinen, Betriebsmitteln, Ladungsträgern und weiteren logistisch relevanten Objekten übertragen werden können. Zum anderen sind auch die Daten aus übergeordneten Steuerungs- und Verwaltungssystemen, wie MES, TMS (Transport Management System) und ERP, zu integrieren. Darüber hinaus sind auch ausgewählte **externe Daten** hinzuzufügen, welche für verschiedene Anwendungsfälle potenziell relevant sind, z. B. Konjunktur-, Verkehrs- und Wetterdaten sowie Daten aus sozialen Netzwerken. Der Bezug der Daten aus den Quellsystemen ist dabei entweder als Batch oder kontinuierlich zu realisieren, wobei Letzteres insbesondere auf Sensorinformationen zutrifft.

Bei der Realisierung der Data Lakes besteht die Möglichkeit einer Verteilung der Daten auf mehrere lokale Speichersysteme, wozu vorgefertigte Architekturen, wie das Hadoop Distributed File System (HDFS) von Apache Hadoop, genutzt werden können. Im Falle stark eingeschränkter Rechenleistungen und Speicherkapazitäten in den Unternehmen wird stattdessen eine **cloud-basierte Realisierung** der Data Lakes empfohlen, wofür eine Vielzahl von externen IaaS mit leistungsbezogenen Preismodellen existieren. Neben dem Zugang zu einer leistungsfähigen und flexiblen Infrastruktur sowie einer Variabilisierung von Fixkosten bietet dieser Ansatz auch die Möglichkeit zur Reduzierung des Implementierungsaufwands.

7.7.2 Digital Twins für kontextbezogene Datenaufbereitung

Ogleich mithilfe der beschriebenen Data Lakes die Aufwände für die Beschaffung von Datenquellen bereits erheblich reduziert werden können, verbleibt für die einzelnen ML-Projekte die Notwendigkeit einer teils sehr arbeitsintensiven Auswahl und Aufbereitung der jeweils relevanten Daten. Dies begründet sich mit der fehlenden datenseitigen Vorstrukturierung und Manipulation, auf die bewusst zur anwendungsübergreifenden Nutzung der integrierten Daten im Lake zu verzichten ist. Unter Berücksichtigung des in Kapitel 5 identifizierten Anwendungs-

spektrums von ML ist jedoch davon auszugehen, dass bestimmte Daten für mehrere Anwendungen benötigt werden. Zur Realisierung von Skaleneffekten bei deren Entwicklung wird daher eine vorausgehende **kontextbezogene Konsolidierung und Aufbereitung dieser Daten** empfohlen. Dazu sind digitale Abbilder zu relevanten logistischen Bezugssystemen der Unternehmen in Form einzelner Objekte, Prozesse, Standorte oder gesamter Netzwerke zu entwickeln, d. h. sog. Digital Supply Chain Twins⁷¹⁸, welche Informationen zu deren **gegenwärtigen und historischen Zustand** bereitstellen. Neben direkten Zustandsinformationen sind dabei auch Daten zu externen Faktoren mit Einfluss auf den Zustand der Bezugssysteme zu integrieren. DT auf Objektebene können Abbilder zur logistischen Infrastruktur, zu Fahrzeugen sowie zu Ladehilfsmitteln, wie z. B. Container, sein. Für diese Objekte sind u. a. vorhandene Sensorinformationen zur Position, zu Stößen, zur internen und externen Temperatur, zur Luftfeuchtigkeit, zum Beladezustand sowie zum Gewicht zu erfassen. Zusätzlich bedarf es einer Integration weiterer Informationen zu daraus abgeleiteten containerbezogenen Zustandseigenschaften, z. B. Prozesszeiten für die Beladung, den Transport und die Entladung, Stand- und Ausfallzeiten sowie die Auslastung bzw. Produktivität der einzelnen Container.

Die technische Umsetzung der DT sieht ebenfalls eine Entwicklung von Modellen vor, welche die einzelnen Informationen zu den Bezugssystemen aus den umfassenden und im Wesentlichen unstrukturierten Datenbeständen der realisierten Data Lakes sowie aus weiteren Systemen in eine realkonforme Beziehung zueinander setzen. Dazu bedarf es einer vorausgehenden Auswahl, Integration und Aufbereitung der relevanten Daten, wobei u. a. Redundanzen, Widersprüche und Anomalien zu eliminieren sind. Anschließend sind die damit verbundenen Logiken in Pipelines zur kontinuierlichen und automatischen Datenbereitstellung für die DT-Modelle zu überführen, womit sich insgesamt hohe inhaltliche Schnittmengen zu den Aktivitäten der zweiten Phase des Vorgehensmodells im HF Ablauforganisation ergeben. Sowohl die aufbereiteten Daten als auch die implementierten **Verarbeitungslogiken der digitalen Abbilder** zu den einzelnen logistischen Bezugssystemen können anschließend von mehreren ML-Anwendungen genutzt werden, sodass sich für die entsprechenden Projekte eine deutliche Aufwandsreduzierung in Bezug auf die notwendigen datenseitigen Aktivitäten ergibt.

7.7.3 Modulare Plattform als Host und Inkubator für ML-Anwendungen

Anstelle der Umsetzung separater ML-Anwendungen und deren klassischer monolithischer Gestaltung sind die zugrundeliegenden Modelle der jeweils angestrebten Anwendungen in ein übergreifendes System mit einer modularen IT-Architektur zu integrieren, welches als **Plattform für die Entwicklung und Ausführung** aller datenbasierten Lösungen der jeweiligen Unternehmen, d. h. einschließlich der zuvor beschriebenen DT-Modelle, fungieren soll (siehe Abbildung 98). Dazu sind die Plattformen über standardisierte Schnittstellen mit den jeweiligen Data Lakes sowie mit allen weiteren anwendungsspezifischen Datenquellen zu verbinden. Zudem sind zentrale technische Komponenten und Funktionen der integrierten Anwendungen

⁷¹⁸ Vgl. Gerlach et al. (2021), S. 5 f.

bzw. Modelle als separate Services verfügbar zu machen, welche von weiteren Anwendungen genutzt werden können. Neben den datenanalytischen Auswertungen und realisierten Pipelines zur Extraktion und Aufbereitung der Daten beinhaltet das auch einen Feature Store (siehe HF Ablauforganisation). Selbiges gilt für die einzelnen modellseitigen Ergebnisse, sodass bspw. die Funktionen der integrierten ML-Modelle als **ML-Services** bereitzustellen sind. Durch diese serviceorientierte Gestaltung der Plattformen können im Falle von daten- oder entwicklungsbezogenen Konvergenzen bedeutende Skaleneffekte bei der Umsetzung von neuen Anwendungen realisiert werden, was sowohl deren modellseitige als auch deren infrastrukturelle Umsetzung betrifft.




Abbildung 98: Aufbau der modularen Plattform für ML-Services⁷¹⁹

Neben der Nutzung für die Aufwandsreduzierung bei der Entwicklung sind die einzelnen Services auch unternehmensinternen Kunden bzw. deren Systemen für die Unterstützung und Ausführung von Entscheidungsprozessen verfügbar zu machen. Dazu bedarf es einer Verbindung der Plattformen mit potenziellen Zielsystemen, wobei standardisierte Schnittstellen mit einer Kompatibilität zu möglichst vielen Anwendungen in den Unternehmen zu nutzen sind, z. B. in Form einer **ESB-Architektur** (Enterprise Service Bus). Dadurch wird es anderen Systemen ermöglicht, die Funktionen der ML-Modelle kontinuierlich zu nutzen, z. B. in Form eines „Abonnements“, was neben der Reduzierung des Integrationsaufwands auch einen positiven Einfluss auf die **Skalierungsmöglichkeit der realisierten Anwendungen** innerhalb der Organisationen nimmt. Ferner sind die Plattformen mit einer eigenen UI auszurüsten, mittels der die einzelnen Services verwaltet, durchsucht und – unabhängig von den Zielanwendungen – ausgeführt werden können, was insbesondere für die Bewertung der Ergebnisse in der Entwicklung von Bedeutung ist.

Analog zum Data Lake besteht bei den Plattformen die Möglichkeit einer lokalen Implementierung. Im Falle eingeschränkter infrastruktureller Voraussetzungen in den jeweiligen Unternehmen wird allerdings auch bei diesen Systemen eine cloud-basierte Realisierung empfohlen,

⁷¹⁹ Eigene Darstellung

wofür wiederum eine Vielzahl von Anbietern mit einem stetig wachsenden Leistungsportfolio zur Verfügung steht. Im Rahmen einer Pay-per-Use-Vergütung und einer Konfiguration der Systeme mittels Infrastructure as Code (IaC) sind dabei die jeweils benötigten **Rechen- und Speicherkapazitäten anpassbar**, sodass auf Erweiterungen der Plattformen um neue Anwendungen flexibel reagiert werden kann. Insgesamt werden mit dieser infrastrukturellen Realisierung zur performanten Ausführung und Speicherung – gemeinsam mit den implementierten Schnittstellen zu relevanten Quell- und Zielsystemen sowie mit den integrierten und erweiterbaren Services – bedeutende Grundlagen für eine effiziente und skalierbare Umsetzung von ML-Anwendungen durch die Plattformen bereitgestellt, sodass diese als ein **technischer „Inkubator“** für entsprechende Vorhaben in den Unternehmen wirken.

7.7.4 Validierung

Für die ML-Anwendung im ETA-Anwendungsfall werden Daten aus einer Vielzahl von IT-Systemen benötigt, die sowohl unterschiedlichen Organisationseinheiten im Unternehmen als auch teilweise externen Instanzen angehören. Intern umfasst das u. a. mehrere Dispositionssysteme für Ist- und Soll-Bewegungsdaten zu den einzelnen Teilprozessen, das TMS für Auftragsinformationen, Systeme mit Daten zur Personalplanung sowie verschiedene Datenbanken mit Informationen zu den genutzten Fahrzeugen. Benötigte Daten aus externen IT-Systemen beziehen sich u. a. auf Bewegungsdaten für die Umschlagsprozesse in den KV-Terminals, auf Informationen zur Schieneninfrastruktur in Form von statischen Eigenschaften und Störungen sowie auf Wetterdaten. Um sowohl bei der Entwicklung als auch beim Betrieb der ETA-Anwendung die benötigten Daten einbeziehen zu können, wird im Voraus ein **Data Lake** im Unternehmen eingerichtet, der verschiedene Daten – welche potenziell für mehrere Anwendungszwecke relevant sind – als Kopie aus den einzelnen Quellsystemen zentral speichert. Neben vordergründig unternehmensinternen Daten werden auch Möglichkeiten zur Integration von Daten aus externen Systemen geprüft, wozu u. a. die angesprochenen Wetterdaten zählen, die neben dem ETA-Anwendungsfall auch für andere Vorhaben nützlich sind. Voraussetzung hierfür ist die Möglichkeit zum regelmäßigen Austausch aktueller Daten, der wie im Falle des Deutschen Wetterdienstes, als Eigentümer der Wetterdaten, über eine Open-API realisiert werden kann. Mit der Umsetzung verschiedener Anwendungen im Unternehmen und den damit gewonnenen Erkenntnissen zu benötigten Daten steigt der Datenumfang des Data Lakes. Neben bisher unberücksichtigten Datenquellen beinhaltet dies im ETA-Anwendungsfall auch eine Anpassung des historischen Horizontes zur Speicherung aller Daten, welche nun rückwirkend für fünf Jahre vorgehalten werden, um auch langfristige Effekte bei der Prognose abbilden zu können.

Zusätzlich zum Data Lake werden mehrere **Digital Twins zu relevanten logistischen Bezugssystemen** des Unternehmens entwickelt, die für unterschiedliche Einsatzbereiche verwendet werden können. Hierzu gehört eine Abbildung der einzelnen Fahrzeuge in Form der

Lkw, Züge und Wagen sowie der Infrastruktur, z. B. der Umschlagstechnik. Im ETA-Anwendungsfall wird die informatorische Grundlage dieser DT zur Reduzierung des Aufwands bei der Vorbereitung der Datenbasis und der Entwicklung der Anwendung verwendet, indem die diesbezüglichen Verarbeitungslogiken der Daten, aber auch teilweise die bereits aufbereiteten Daten selbst übernommen werden.

Zur Ausführung der ETA-Anwendung werden deren ML-Modelle zusammen mit weiteren datenbasierten Lösungen in ein zentrales System überführt, welches unter Nutzung von externer Cloud-Infrastruktur mittels IaaS eingerichtet wurde. An diese **Plattform** sind sowohl der realisierte Data Lake als auch weitere benötigte IT-Systeme angeschlossen. Die Daten auf der Plattform werden anhand anwendungsspezifischer Anforderungen automatisch aufbereitet, wobei die diesbezüglichen Logiken und Pipelines übergreifend genutzt und weiterentwickelt werden. Die systemseitigen Ergebnisse der ETA-Modelle in Form der jeweiligen Ankunftszeitprognosen werden über den ESB des Unternehmens bereitgestellt, sodass sie durch alle angebotenen Bereiche als „**ETA-Service**“ abrufbar sind. Dazu gehören u. a. verschiedene Logistikbereiche, aber auch die Personalabteilung und der Vertrieb, welcher die Informationen wiederum zur Weitergabe an die Kunden nutzt.

Nach Prüfung dieses HF anhand des ETA-Anwendungsfalls lässt sich eine Operationalisierung aller wesentlichen Aktivitäten sowie eine Erfüllung von sieben Anforderungen feststellen (siehe Tabelle 31).

Anforderung	Erfüllung im Anwendungsfall durch Maßnahmen des HF
Datenverfügbarkeit	Durch den initialen Bezug historischer Datensätze sowie die kontinuierliche Speicherung aktueller Daten durch den Data Lake sind viele der benötigten Daten für die ML-Anwendung zentral verfügbar.
Datenqualität	Bei der Integration in den Data Lake und bei der Entwicklung der Digital Twins werden die Daten auf Anomalien überprüft. Fehlerhafte Daten schränken die angestrebte Abbildung der Realität ein und führen zu Anpassungsmaßnahmen.
IT-Vernetzung	Der Data Lake ersetzt die Vernetzung vieler Einzelsysteme. Zusammen mit anderen Datenquellen ist er mit der Plattform verbunden, welche wiederum die einzelnen systemseitigen Ergebnisse an andere Zielsysteme mittels des ESB bereitstellt.
Skalierbarkeit	Die modulare Plattform gewährleistet eine Weiternutzung von bestehenden Daten, Systemkomponenten und Infrastruktur durch die ML-Anwendung. Die systemseitigen Ergebnisse werden zudem als Service für alle Unternehmensbereiche bereitgestellt.
IT-Performance	Die Nutzung externer Cloud-Infrastruktur von renommierten Anbietern für den Betrieb der Plattform gewährleistet eine Bereitstellung der für die Ausführung der ML-Anwendung benötigten Rechenleistung.
Verfügbarkeit	Die Nutzung externer Cloud-Infrastruktur von renommierten Anbietern für den Betrieb der Plattform gewährleistet eine nahezu permanente Verfügbarkeit der ML-Anwendung.
Manipulations-sicherheit	Die Nutzung externer Cloud-Infrastruktur von renommierten Anbietern für den Betrieb der Plattform schränkt die Möglichkeiten eines unbefugten Zugriffs ein.

Tabelle 31: Handlungsfeld Datenmanagement – Erfüllung der Anforderungen

7.8 Zusammenfassung der Ergebnisprüfung

Bei einer Gesamtbetrachtung der operationalisierten Maßnahmen des Gestaltungsansatzes ist festzustellen, dass alle damit verbundenen Inhalte auf den verwendeten Anwendungsfall übertragbar sind. Dies gilt sowohl für die einzelnen Aktivitäten als auch für empfohlenen Methoden und Dokumente, was u. a. eine Einordnung der Anwendung in die ML-Typologie betrifft. Auch liegen keine inhaltlichen Widersprüche und Redundanzen zwischen den Maßnahmen vor. Stattdessen führen die einzelnen Aktivitäten, einschließlich der Schritte des Vorgehensmodells, zu einem durchgehend schlüssigen Ablauf. Zusammenfassend gilt damit die **Anwendbarkeit des Gestaltungsansatzes** für das Untersuchungsfeld als praktisch bestätigt.

Anhand der Prüfung der Anforderungen anhand der operationalisierten Maßnahmen ist zu erkennen, dass durch die einzelnen HF jeweils mehrere Anforderungen erfüllt werden. Nach Zusammenführung dieser Ergebnisse ist festzustellen, dass jede Anforderung durch mindestens ein HF bzw. die darin enthaltenen Maßnahmen adressiert wird (siehe Tabelle 32). Darüber hinaus liegt in einigen Fällen auch eine Mehrfachabdeckung vor. Hierbei handelt es sich zum Großteil um Anforderungen, die entsprechend der Priorisierung in Kapitel 6.5.4 eine vergleichsweise hohe Bedeutung aufweisen, sodass eine schwerpunktmäßige Berücksichtigung in der Praxis als zweckmäßig erachtet wird. Insgesamt konnten dadurch auch der Nutzen und dementsprechend die **Erfolgswirkung des Gestaltungsansatzes** praktisch bestätigt werden.

Priorität	Anforderung	Art	HF 1	HF 2	HF 3	HF 4	HF 5	HF 6	Σ
1	Skalierbarkeit	S		x				x	2
	Interdisziplinäre Kooperation	U		x	x				2
	Personal und Finanzen	U	x		x		x		3
	Standardprozesse	U	x	x			x		3
	Strategische Vorgaben	U	x						1
	Governance	U	x						1
	Akzeptanz	U			x	x	x		3
	Komplexitätsbeherrschung	U		x					1
2	Transparenz	U	x	x					2
	Zuverlässigkeit	S		x	x		x		3
	Manipulationssicherheit	S						x	1
	Compliance	S			x				1
	Kontrollierbarkeit der Entscheidung	S				x			1
	Datenverfügbarkeit	U						x	1
	Datenqualität	U					x	x	2
	IT-Performance	U						x	1
3	IT-Vernetzung	U						x	1
	Business Case	S		x					1
	Verfügbarkeit	S						x	1
	Nachvollziehbarkeit	S				x			1
	Systemdenken	U		x	x				2
	Kompetenz	U					x		1

4	Strategic Fit	S	x	1
	Kontrollierbarkeit des Lernprozesses	S	x	1

Legende: S = Systemeigenschaften U = Umfeldeigenschaften

Tabelle 32: Erfüllung der Anforderungen durch den Gestaltungsansatz

Infolge der Bestätigung beider Validierungskriterien wird das mit der Entwicklung des Gestaltungsansatzes verbundene Ziel einer Befähigung von Unternehmen zum erfolgreichen Einsatz von ML-Anwendungen im Logistikmanagement als erfüllt angesehen – was gleichzeitig einem Erreichen des übergeordneten Forschungsziels der vorliegenden Arbeit entspricht. Der Gestaltungsansatz stellt demnach ein für diesen Einsatzzweck **geeignetes Unterstützungsinstrument** dar, welches nach Einschätzung des Autors die Maßnahmen mit den höchsten Erfolgswirkungen aufzeigt, sodass diese von den Unternehmen prioritär zu realisieren sind.

Gleichzeitig ergeben sich für die praktische Nutzung dieses Instrumentes mehrere Einschränkungen, die im Zusammenhang mit den Prämissen der vorliegenden Untersuchung stehen. Demnach ist das Spektrum der bereitgestellten Maßnahmen und der damit verbundenen Umsetzungsaktivitäten aufgrund der bei der Entwicklung notwendigen **Generalisierung** realer Phänomene als nicht abschließend anzusehen. Stattdessen bedarf es bei der praktischen Überführung einer weiteren Detaillierung gemäß der jeweiligen unternehmens- und anwendungsspezifischen Rahmenbedingungen. Hieraus können sich auch abweichende Schwerpunkte und zusätzliche Handlungsbedarfe ergeben. Auf diese unterschiedlichen Voraussetzungen in Unternehmen wurde aus Komplexitätsgründen nicht eingegangen. Selbiges gilt für individuelle Anforderungen einzelner Lernverfahren und darauf basierender Anwendungen, welche nur punktuell Berücksichtigung fanden. Stattdessen wurde ML in der Gesamtheit gemäß der Systematisierung in Kapitel 2.4.3 betrachtet. Entsprechend des Forschungsziels der vorliegenden Arbeit ging mit der Entwicklung der Maßnahmen zudem eine Fokussierung auf Aktivitäten mit einer tendenziell **ML-spezifischen Ausprägung** einher. Auf die Darstellung notwendiger technologieübergreifender Unterstützungstätigkeiten wurde dagegen weitestgehend verzichtet. Neben Projektmanagementaufgaben betrifft dies auch „klassische“ IT-Aktivitäten, wie das Einrichten von Datenbanken oder Schnittstellenprogrammierungen, welche nicht Teil der Untersuchungen waren (siehe Kapitel 1.2). Vor diesem Hintergrund wurden ethische und rechtliche Maßnahmen ebenfalls nur tangiert. Auf Grundlage der Erkenntnisse zur branchenweiten Bedeutung von ML für das Logistikmanagement in Verbindung mit den notwendigen Voraussetzungen für eine Generierung von nachhaltigen Wettbewerbsvorteilen im Sinne der ressourcentheoretischen Ansätze (siehe Kapitel 2.1.2) liegt dem Gestaltungsansatz zudem das Szenario einer **langfristigen Etablierung** von ML in Unternehmen zugrunde, was gleichzeitig mit einer weitestgehenden Eigenentwicklung der Anwendungen einhergeht.

8 Fazit

Das Forschungsziel der vorliegenden Arbeit bestand in der Befähigung der Praxis zur Gestaltung eines erfolgreichen Einsatzes von ML-Anwendungen im Logistikmanagement. In diesem Kapitel werden die damit verbundenen Ergebnisse reflektiert, was zu Beginn deren Zusammenfassung beinhaltet (Kapitel 8.1). Anschließend werden die Ergebnisse einer kritischen Bewertung unterzogen (Kapitel 8.2), um darauf basierend weitere Forschungsbedarfe auszuweisen (Kapitel 8.3).

8.1 Zusammenfassung

Als ein Teilbereich der Künstlichen Intelligenz weist Machine Learning eine bis auf die 1950er Jahre zurückgehende Forschungshistorie auf. Bereits kurz nach dem Aufkommen der Informationstechnik wurde die Möglichkeit – sowie gleichzeitig auch die Notwendigkeit – gesehen, Computer zum **eigenständigen Lernen** auf Basis von Daten zu befähigen, anstatt stets das erforderliche Wissen für die Lösung von Problemen manuell zu programmieren (siehe Kapitel 2.4). In Ermangelung der benötigten Rechenleistungen und Daten war die Nutzung dieses Ansatzes jedoch im industriellen Kontext lange nur sehr eingeschränkt möglich. Seit den 2010er Jahren haben sich diese Voraussetzungen deutlich verbessert, was branchenübergreifend zu einem Bedeutungsanstieg der Technologie geführt hat. In der vorliegenden Arbeit konnte diese Entwicklung auch für die Logistik festgestellt werden. Demnach ist nach Befragung einer Vielzahl von Praxisvertretern im Rahmen einer mehrstufigen empirischen Untersuchung zu konstatieren, dass ML als **Schlüsseltechnologie** für diesen Bereich mit einem hohen Einfluss auf die zukünftige Wettbewerbsfähigkeit der Unternehmen wahrgenommen wird (siehe Kapitel 4.2). Bei den Bestrebungen zur Nutzbarmachung von ML in der logistischen Praxis lässt sich bislang eine Fokussierung auf Aufgaben der operativen Leistungserstellung beobachten, wozu u. a. die Erkennung von Sprache und Bildern sowie der (semi-)autonome Betrieb von Fahrzeugen bzw. Maschinen zur Verrichtung „physischer“ Tätigkeiten zählen. Darüber hinaus konnte ein hohes Potenzial für den Einsatz von ML zur **Unterstützung und Ausführung von Entscheidungsprozessen** in Form der Planung, Steuerung und Überwachung festgestellt werden, dessen erfolgreiche Nutzung jedoch ein bisher größtenteils unerschlossenes Forschungsfeld darstellt (siehe Kapitel 4.1).

Für die unter dem Begriff des Logistikmanagements subsumierten Aufgaben zeigt das identifizierte Anwendungsspektrum, dass bereits eine Vielzahl von Problemstellungen zuverlässig mittels ML gelöst werden können (siehe Kapitel 5.2). Durch das Zusammenspiel von relevanten Daten zu den jeweiligen Phänomenen, einer geeigneten Modellierung der mathematisch-statistischen Lernverfahren sowie – als Grundlage für beiden erstgenannten Faktoren – einer Einbindung von Prozesswissen sind die realisierten ML-Anwendungen in der Lage, **komplexe empirische Zusammenhänge zu erkennen** und zur Lösung von bisher unbekanntem Fällen

anzuwenden. Hieraus lassen sich mehrere Problemlösungsfähigkeiten von ML für das Logistikmanagement ableiten, welche in vielen Anwendungsfällen deutliche Leistungsvorteile gegenüber dem Menschen und den bisherigen Entscheidungstechniken erkennen lassen. Demnach sind ML-Anwendungen, z. B. unter Verwendung von Unsupervised und Deep Learning, zur präzisen **Identifikation** von Störungen und Risiken in Logistikprozessen sowie zur **Analyse** tieferliegender Ursachen einsetzbar. Auch ist es z. B. unter Nutzung von Supervised Learning möglich, diese Ergebnisse und weitere bedeutende Planungsparameter, wie das zukünftige Bestellverhalten sowie die voraussichtliche Durchlaufzeit von Prozessen, trotz des dynamischen Einflusses von vielen Faktoren mit nichtlinearen Beziehungen verlässlich zu **prognostizieren**. Auch für Problemstellungen mit mehreren konfliktären Zielgrößen können, z. B. durch den Einsatz von Reinforcement und Evolutionary Learning, **optimale Lösungen** ermittelt werden, was u. a. für die Maschinenbelegung und die Disposition von Materialumfängen von hoher Bedeutung ist. Die systemseitig generierten Entscheidungen stellen dabei teils neue, bisher unerschlossene Lösungswege dar. Diese „kreativen“ Fähigkeiten von ML werden durch bedeutende Forschungstrends, wie die Generative Adversarial Networks (siehe Kapitel 4.4), langfristig eine Verbesserung erfahren und damit zukünftig auch für die Gestaltung von Produktions- und Logistikprozessen nutzbar werden.

Im Falle eines gezielten Einsatzes dieser Fähigkeiten lassen sich bedeutende Veränderungen für die Logistik erwirken (siehe Kapitel 5.4). Durch die verbesserten Möglichkeiten zur Antizipation zukünftiger Ereignisse, zu denen neben Störungen auch veränderte Kundenanforderungen zählen, können Maßnahmen vorausschauend initiiert und damit **Logistikprozesse zuverlässig und bedarfsgerecht** gestaltet werden. Der systemseitige Umgang mit einer hohen Informationsvielfalt erlaubt dabei ganzheitliche Planungen über mehrere vormals separat betrachtete Entitäten, was u. a. für eine Harmonisierung von Beständen über mehrere Lieferstufen in Form einer **Netzwerksteuerung** genutzt werden kann. Entsprechend der technischen Möglichkeiten von ML-Anwendungen, das Systemverhalten adaptiv auf veränderte Umweltsituation anzupassen, besteht – neben dem bisher dominierenden Einsatz als Entscheidungsunterstützung – auch ein hohes Potenzial zur autonomen Ausführung von Entscheidungsprozessen (siehe Kapitel 6.2). Neben der Objektivierung von Entscheidungen und der damit verbundenen Fehlerreduktion ergibt sich hierdurch die Möglichkeit zur Realisierung **selbststeuernder Prozesse und Teilsysteme** mit hohen Effizienz- und Produktivitätssteigerungen.

Entgegen der strategischen Bedeutung war jedoch bei den Untersuchungen festzustellen, dass die Potenziale von ML für das Logistikmanagement bisher nur vereinzelt in der Praxis erschlossen wurden. Vielmehr befindet sich die Mehrheit der Unternehmen noch in einer **Beobachtungs- und Planungsphase** und fühlt sich zusätzlich nur unzureichend auf die Adoption der Technologie vorbereitet (siehe Kapitel 4.2). Ausgehend von einem zu beobachtenden Wissensdefizit in Bezug auf zentrale Fragestellungen für einen Einsatz von ML wurde im Rahmen einer systematischen Anforderungsanalyse erkannt, dass die dafür notwendigen Voraussetzungen in den Unternehmen bisher nur unzureichend vorliegen (siehe Kapitel 6). Diese

Einschränkungen hemmen eine weitere Ausbreitung der Technologie in der Logistikbranche und führen gleichzeitig dazu, dass die realisierten ML-Anwendungen – trotz technisch vielversprechender Ansätze – **hinter den wirtschaftliche Erwartungen zurückbleiben**. Stattdessen stellen sie häufig Insellösungen ohne größere Skalierungsmöglichkeiten dar und verbleiben in einem prototypischen Zustand. Zur Begegnung dieses Handlungsbedarfs wurden unter Berücksichtigung der domänen- und technologiespezifischen Rahmenbedingungen prioritär zu realisierende Maßnahmen für den erfolgreichen Einsatz von ML im Logistikmanagement ermittelt (siehe Kapitel 7).

Zur Sicherstellung der technischen Grundlage von ML-Anwendungen und zur Begegnung des damit verbundenen Aufwands, welcher teilweise bis zu 80 % der Tätigkeiten von ML-Projekten ausmacht, sind die jeweils benötigten Daten bereitzustellen. Ausgehend von primär historischen Daten im Rahmen der Entwicklung erweitern sich diese Bedarfe im Betrieb auf Echtzeitdaten. Obwohl die grundsätzlich verfügbaren Daten bereits eine Realisierung von ML-Anwendungen für viele logistische Problemstellungen zulassen würden, ist festzustellen, dass den jeweiligen Projekten die Zugangsmöglichkeiten zu den entsprechenden Daten fehlen. Einen wesentlichen Grund stellt die funktionale Organisationsstruktur von Unternehmen dar, die zu einer Ausbildung von „Datensilos“ in Bezug auf die IT-Systemlandschaft geführt hat. Diese dezentrale Verteilung der benötigten Datenquellen ist im Falle der Logistik entsprechend ihrer Querschnittsfunktion in einem besonderen Maße ausgeprägt. Neben einer weiteren Erhöhung der Datenverfügbarkeit durch die Digitalisierung von Prozessen wird daher als eine bedeutende Maßnahme die **Integration von Unternehmensdaten** – angereichert um verfügbare externe Daten – in Form von Data Lakes gesehen. Neben einem verbesserten Zugang kann damit der Beschaffungs- und Integrationsaufwand für die einzelnen ML-Projekte erheblich reduziert werden. Für zusätzliche Effizienzsteigerungen bei der Datenaufbereitung sind außerdem **digitale Abbilder von logistischen Objekten und Prozessen** der Unternehmen durch eine kontextbezogene Zusammenführung der jeweiligen Daten zu implementieren. Deren Verarbeitungslgorithmen können anschließend durch ML-Projekte nachgenutzt werden.

Neben diesen technischen bedarf es auch entsprechender personeller Ressourcen zur Umsetzung von ML-Anwendungen. Die dafür benötigten Qualifikationsprofile, welche häufig über die vorhandenen Kompetenzen von Industrieunternehmen hinausgehen, umfassen neben Programmiererfahrungen in mehreren für ML relevanten Entwicklungsumgebungen auch Kenntnisse in Statistik und Mathematik sowie ein Verständnis über logistische Zusammenhänge. Aufgrund des strukturellen Mangels an entsprechenden Fachkräften am nationalen und internationalen Arbeitsmarkt, z. B. in Form von Data Scientists und Data Engineers, ist eine externe Rekrutierung nur begrenzt möglich. Somit sind ergänzend bestehende Mitarbeiter zu qualifizieren sowie Kooperationen mit anderen Unternehmen und Forschungseinrichtungen einzugehen. Entsprechend der strategischen Bedeutung von ML ist Letzteres jedoch nur im Sinne eines langfristigen **Aufbaus von eigenem Wissen** zu betreiben, weshalb auch eine vollständige Fremdvergabe der Anwendungsentwicklung zu vermeiden ist.

Im Gegensatz zu konventioneller Software werden bei ML-Anwendungen – auch über eine initiale Anforderungserhebung hinaus – während des gesamten Umsetzungsprozesses zusätzliche Wissensträger zu den jeweils adressierten Geschäftsprozessen benötigt, u. a. um Datenauswertungen und Modellergebnisse zu validieren sowie um Verbesserungsmöglichkeiten in Form weiterer Features und Daten zu identifizieren. Zu den zeitlichen und personellen Aufwänden können allerdings im Voraus nur indikative Aussagen getätigt werden. Dies begründet sich mit der Unsicherheit über den jeweils optimalen Lösungsweg, der von den verfügbaren Daten sowie dem spezifischen Verhalten der Lernverfahren abhängt, und vielmehr eine experimentelle **Erprobung verschiedener Ansätze** im Sinne eines Trial-and-Error-Vorgehens bedingt. Um diesen Flexibilitätsbedarfen von ML-Projekten – sowohl bei der Einbindung der benötigten Mitarbeiter für die Entwicklung und die Bereitstellung des Prozesswissens als auch bei der Lösungsgestaltung – gerecht zu werden, sind **dezentrale Organisationsstrukturen** mit einer Entscheidungsautonomie für die Projektteams zu realisieren. Einen geeigneten Ansatz stellt das Spotify-Modell dar, welches die Skalierung agiler Prinzipien der Softwareentwicklung auf größere Organisationseinheiten ermöglicht, ohne dass die Strukturen bestehender Linienorganisationen vollständig aufgelöst werden. Gleichzeitig ergeben sich dadurch formelle und informelle Vernetzungsmöglichkeiten für die Projekte bzw. die jeweiligen Mitarbeiter, was entsprechend der Neuartigkeit von ML zum Wissensaustausch und zur Erzeugung neuer Innovationen benötigt wird. Zur Vermeidung einer Entkopplung von den adressierten Geschäftsprozessen ist – entgegen der aktuell vorherrschenden Verankerung der ML-Projekte in Innovationsabteilungen, bei denen es sich teilweise auch um ausgelagerte Labs handelt – die damit verbundene **Verantwortung auf den IT-Bereich** zu übertragen, welcher gemäß des Spotify-Modells zu organisieren ist.

Entsprechend der Unsicherheit über den jeweils besten Lösungsweg ist bei bisherigen ML-Projekten zu beobachten, dass sich die Verantwortlichen – auch motiviert durch deren wissenschaftliche Prägung – häufig in der Optimierung von Details „verlieren“, was zu langen Entwicklungszeiten, aber auch zu einer Abweichung von den eigentlich zu lösenden Problemen führt. Um trotz des notwendigen experimentellen Vorgehens eine Wirtschaftlichkeit der Vorhaben sicherzustellen, bedarf es einer **systematischen Auswahl und Umsetzung** geeigneter Anwendungen. Zur Etablierung eines entsprechenden Standardprozesses eignet sich das in der vorliegenden Arbeit entwickelte Vorgehensmodell. Ausgehend von einer initialen Betrachtung und Zielformulierung für den finalen Zustand der angestrebten ML-Anwendungen sieht dieser Prozess eine bewusste **Reduzierung der Systemkomplexität** mittels mehrerer Entwicklungsstufen im Sinne eines Prototyping vor. Hierdurch wird die benötigte Entwicklungsumgebung für eine Erprobung verschiedener Lösungsansätze geschaffen sowie gleichzeitig ein schneller Erkenntnisgewinn zur grundsätzlichen Realisierbarkeit, zum bestmöglichen Ansatz sowie zu den erzielbaren Potenzialen sichergestellt. Die dafür notwendige **Fortschrittskontrolle** wird mittels der Strukturierung des Prozesses in mehrere Quality Gates ermöglicht.

Neben den genannten technischen und organisatorischen Maßnahmen ist auch gezielt den nicht zu vernachlässigenden sozialen Implikationen beim Einsatz von ML-Anwendungen zu begegnen. Dies betrifft zuvorderst die negative Einstellung vieler Mitarbeitern gegenüber der Technologie, welche im Zusammenhang mit den Fähigkeiten der Systeme zur eigenständigen Anpassung ihres Verhaltens sowie deren Black-Box-Charakter infolge der subsymbolischen Wissensverarbeitung steht. In Abhängigkeit des jeweiligen Autonomiegrads ergeben sich zudem auch größere Veränderungen für das ursprüngliche Aufgabenspektrum der Mitarbeiter, indem Entscheidungsumfänge an die Systeme abgegeben werden und gleichzeitig neue Kontrollaufgaben hinzukommen. Neben einem Verlust von Problemlösungsfähigkeiten kann diese Entwicklung als Degradierung wahrgenommen werden und zu Ängsten in Bezug auf den Verlust der eigenen Arbeit führen. Um bei den betroffenen Mitarbeitern dennoch eine Akzeptanz gegenüber dem Einsatz von ML sicherzustellen und sie gleichzeitig für die Ausführung der veränderten Aufgaben zu befähigen, bedarf es entsprechender **Qualifizierungsmaßnahmen**. Dazu sind zum einen regelmäßige Schulungen durchzuführen, in denen grundsätzlich die Bedeutung und Funktionsweise von ML sowie das Verhalten der jeweiligen Anwendungen vermittelt werden. Letzteres impliziert auch ein Verständnis über systemseitige Fähigkeiten und Grenzen, um Entscheidungssituationen beurteilen zu können, in denen ein menschliches Eingreifen notwendig ist. Zum anderen sind ausgewählte Nutzer in den Umsetzungsprozess der Anwendungen im Sinne eines **User-Community-Ansatzes** einzubeziehen. Dies dient dem Verständnissgewinn zum Systemverhalten und stellt gleichzeitig eine Berücksichtigung der nutzerseitigen Anforderungen bei der Anwendungsgestaltung sicher.

In Hinblick auf eine Übernahme von vormals manuellen Entscheidungsumfängen durch ML-Anwendungen bedarf es zudem einer vorausgehenden Beantwortung von übergreifenden ethischen Fragstellungen zur zukünftigen Rolle der bisherigen Mitarbeiter. Anstelle eines größeren Arbeitsplatzabbaus empfiehlt sich hierfür eine Orientierung an einem **menschenzentrierten Leitbild**, welches den Einsatz von ML als sinnvolle Ergänzung der menschlichen Stärken vorsieht. Dazu sind auch die jeweils freiwerdenden zeitlichen Kapazitäten bei den Mitarbeitern für eine **horizontale und vertikale Erweiterung** des bisherigen Aufgabenspektrums zu nutzen. Durch die damit einhergehende Erhöhung des Betrachtungs- und Gestaltungsbereiches werden die Mitarbeiter zur ganzheitlichen Bewertung und Lösung von Problemen befähigt, was neben einer Motivationssteigerung auch langfristige positive Effekte auf die Innovationsfähigkeit und Produktivität der Unternehmen hat. Gleichzeitig ist im Rahmen dieser strategischen Vorüberlegungen auch der angestrebte Technologieeinsatz im Sinne der Unternehmensziele festzulegen. Hierfür ist initial eine **Vision** zu entwickeln, in der die realisierbaren Potenziale und zu vermeidenden Risiken von ML berücksichtigt sind. Zusätzlich bedarf es eines **Strategieplans** in Form einer Roadmap, welcher die notwendigen Aktivitäten zum Erreichen dieses Zielbildes enthält, wozu auch eine Vorauswahl von strategisch relevanten ML-Anwendungsfällen mit entsprechenden Entwicklungspfaden zählt.

Die im Rahmen der vorliegenden Arbeit empfohlenen Maßnahmen, einschließlich des Vorgehensmodells, wurden in Form eines **Gestaltungsansatzes** strukturiert und anhand eines realen Anwendungsfalls in Bezug auf ihre Erfolgswirkung überprüft. Infolge einer damit einhergehenden Ergebnisbestätigung stellt der Gestaltungsansatz ein geeignetes Unterstützungsinstrument für die Befähigung der Praxis zum Einsatz von ML im Logistikmanagement dar. Zusammen mit den ebenfalls bereitgestellten Informationen zu den technischen Grundlagen und den erwarteten Entwicklungen von ML sowie zu den realisierbaren Anwendungsfällen und den damit erzielbaren Nutzenpotenzialen können Führungskräfte aus dem logistischen Umfeld auf Grundlage der vorliegenden Arbeit systematisch das notwendige **Technologiewissen für fundierte Entscheidungen** zur Gestaltung des Adoptionsprozesses aufbauen (siehe Kapitel 2.1.3.1). Entsprechend des Spektrums der abgedeckten Gestaltungsbereiche leistet die Arbeit gleichzeitig einen Beitrag zur Schaffung notwendiger infrastruktureller, organisatorischer und sozialer Voraussetzungen für die **digitale Transformation** von Unternehmen.

8.2 Kritische Würdigung

Mit dem Untersuchungserfolg gehen auch einzelne Einschränkungen zur Aussagefähigkeit und Gültigkeit der erzielten Ergebnisse einher, welche im Zusammenhang mit den Zielsetzungen, dem festgelegten Untersuchungsfeld und dem Forschungsdesign der vorliegenden Arbeit stehen. Eine Einschränkung betrifft das bei der Entwicklung des Gestaltungsansatzes betrachtete **Szenario der logistischen Praxis**. Demnach wurden sowohl für die Ausgangssituation als auch für den zu realisierenden Sollzustand repräsentative Ausprägungen für diesen Bereich angenommen, welche sich zum Großteil auf das aggregierte Meinungsbild der befragten Praxisvertreter zur Bedeutung und zum derzeitigen Umsetzungsstand der benötigten System- und Umfeldeigenschaften beziehen. Entsprechend der ressourcentheoretischen Erkenntnisse zur Erzielung von nachhaltigen Wettbewerbsvorteilen und der empirischen Ergebnisse zur Bedeutung von ML für die Logistik wurde zudem vor einer langfristigen Integration der Technologie in die Organisationen ausgegangen. In der Praxis können die individuellen Rahmenbedingungen der jeweiligen Unternehmen jedoch teils erheblich von diesem Referenzszenario abweichen. Demnach wurden bereits im Rahmen der vorliegenden Untersuchung stärkere Unterschiede in den Unternehmen festgestellt, z. B. in Bezug auf den Fortschritt bei der Integration von Daten sowie bei der organisatorischen Verankerung von ML-Projekten und deren internen Zugriffsmöglichkeiten auf die benötigten Ressourcen. Auch wurde erkannt, dass nicht alle Unternehmen der Technologie dieselbe Bedeutung beimessen, sodass davon auszugehen ist, dass in vielen Fällen auch langfristig nur Bestrebungen zur Umsetzung vereinzelter Anwendungen bestehen werden. Eine differenzierte **Betrachtung dieser unterschiedlichen Zielsetzungen und Voraussetzungen** wurde in der Arbeit jedoch aus Komplexitätsgründen nicht vorgenommen. Dennoch wird erwartet, dass sich aus der Gesamtheit der empfohlenen Maßnahmen unterschiedliche Schwerpunkte für die jeweilige praktische Umsetzung ergeben, wo-

bei einzelne Maßnahmen unter bestimmten Rahmenbedingungen auch obsolet werden können. Gleichzeitig wird auch ein Bedarf von Aktivitäten entstehen, welche nicht durch den Gestaltungsansatz abgedeckt sind.

Eine weitere Einschränkung der Arbeit steht im Zusammenhang mit der zeitlichen Veränderlichkeit des Untersuchungsfeldes. Im Rahmen der Untersuchung wurden ausgehend von der aktuellen Situation mehrere **hemmende und unterstützende Entwicklungen** mit einem Einfluss auf die Ausprägungen des Untersuchungsfeldes identifiziert. Dies betrifft sowohl die zukünftigen Fähigkeiten von ML, welche sehr dynamischen Forschungsaktivitäten unterliegen, sowie Veränderungen der technischen, organisatorischen und rechtlichen Voraussetzungen im logistischen Umfeld. Demnach werden insbesondere für die Lösung von Problemstellungen mit kleineren Datenmengen substantielle Verbesserungen erwartet, u. a. durch weitere Fortschritte im Bereich des Reinforcement und Transfer Learning. Auch ist im Sinne des postulierten Ziels der dritten Welle von KI von einer erhöhten Nachvollziehbarkeit zukünftiger ML-Anwendungen auszugehen. Zudem wird sich das Angebot von AutoML-Services voraussichtlich auch auf die Logistik erweitern, sodass Komponenten und Teilaufgaben für die Umsetzung entsprechender Anwendungen „on-demand“ für die Unternehmen beziehbar sind. Dies kann u. a. die aktuell notwendigen Maßnahmen zur Bereitstellung von großen Datenmengen, zum Aufbau eigener Kompetenzen und zur Schaffung von Akzeptanz gegenüber der Technologie verändern. Ferner sind dadurch auch substantielle Auswirkungen auf die realisierbaren Anwendungsfälle von ML im Logistikmanagement zu erwarten. Auch wenn im Rahmen des Forschungsprozesses diese potenziellen Veränderungen bereits eine Berücksichtigung fanden, sind ihre tatsächlichen Auswirkungen **aus heutiger Sicht nicht vollumfänglich antizipierbar**. Somit ist die langfristige Gültigkeit der erzielten Ergebnisse in Form der Anwendungsmöglichkeiten, der Anforderungen und damit auch der empfohlenen Maßnahmen mit einer nicht unwesentlichen Unsicherheit behaftet.

Im Einklang mit dem Forschungsziel wurde das Untersuchungsfeld der vorliegenden Arbeit bewusst in Bezug auf eine technische und prozessuale Dimension in Form von ML und dem Logistikmanagement eingeschränkt. Auf Grundlage der damit verbundenen definitorischen Abgrenzung konnten die benötigten Informationen gezielt für beide Dimensionen erhoben und dabei das Risiko einer Verzerrung der Ergebnisse durch die Berücksichtigung nicht relevanter Ausprägungen gemindert werden. Insbesondere für die technische Dimension wurde dieser Ansatz infolge einer oft uneinheitlichen bis „diffusen“ Betrachtung von ML als notwendig erachtet. Mit dieser bewussten Begrenzung gehen jedoch auch potenziell nachteilige Effekte einher, indem bestehende **Wechselwirkungen mit anderen Unternehmensbereichen und Technologien** unterrepräsentiert bleiben. Demnach existieren in der Forschung und Praxis diverse Bestrebungen zur Verbindung von ML mit anderen technischen Ansätzen, z. B. in Form von Digital Twins oder kognitiven Systemen durch die Integration von modellbasierten Ansätzen. Auch zeigen sich Wechselwirkungen mit anderen KI-Bereichen, wie in Form von

Computer Vision und NLP, welche jedoch jeweils nur punktuell betrachtet wurden. Insbesondere in Hinblick auf die zukünftige Realisierung definitionsgemäßer „intelligenter“ Systeme, welche über Fähigkeiten der Wahrnehmung, des Lernens und verschiedener Aktionsformen verfügen, sind solche integrierten Betrachtungen allerdings von hoher Bedeutung.

Trotz der vorgenommenen Begrenzung repräsentiert das gewählte Untersuchungsfeld weiterhin ein breites technisches und prozessuales Spektrum. Entsprechend des Anspruches, dieses im Sinne eines initialen Gesamtüberblicks wissenschaftlich zu erschließen, wurde jedoch auf eine **differenzierte Untersuchung einzelner Teilbereiche** von ML und des Logistikmanagements verzichtet. Spezifische Anforderungen von bestimmten Lerntypen bzw. -verfahren sowie von logistischen Anwendungsfällen fanden daher nur eine eingeschränkte Betrachtung. Aus diesem Anspruch heraus wurden ebenfalls nahezu alle empirisch erhobenen Anforderungen bei der Definition eines zu realisierenden Zielzustandes für die Entwicklung des Gestaltungsansatz berücksichtigt. Mit dem interdisziplinären Spektrum der resultierenden Gestaltungsbereiche, welche von technischen Maßnahmen über notwendige organisatorische und soziale Veränderungen bis hin zu strategischen Aktivitäten reichten, ging jedoch gleichzeitig eine **Einschränkung des realisierbaren Detailgrades** bei der Ergebnisdarstellung einher. Auch wenn die entwickelten Maßnahmen eine wichtige Orientierung für Unternehmen bei der Gestaltung des Technologieeinsatzes darstellen, bedarf es im Falle einer praktischen Umsetzung daher weiterer Aktivitäten.

Über die bereits genannten inhaltlichen Punkte hinaus ergeben sich auch aus der Methodik der vorliegenden Arbeit ergebnisbezogene Einschränkungen. Dies betrifft zuvorderst den gewählten Validierungsansatz in Form der nachträglichen „Operationalisierung“ der entwickelten Maßnahmen anhand eines realen Anwendungsfalles. Auch wenn dieser Ansatz die Anwendbarkeit und Zweckmäßigkeit bestätigt, kann in **Ermangelung einer fehlenden praktischen Erprobung** keine endgültige Aussage zum empirischen Erfolg der erzielten Ergebnisse getroffen werden. Darüber hinaus bestehen auch Einschränkungen im Zusammenhang mit den durchgeführten Befragungen im Rahmen der empirischen Untersuchung. Trotz einer hohen Sorgfalt bei der Auswahl der Teilnehmer und der Auswertung der Ergebnisse repräsentieren die erhobenen Meinungsbilder grundsätzlich subjektive Ausschnitte der Realität, welche durch bewusste oder unbewusste Über- und Unterschätzungen von Phänomenen geprägt sein können. Hinsichtlich des Teilnehmerkreises ist zudem festzustellen, dass vermehrt Großunternehmen involviert waren, sodass die Sichtweisen von **kleineren und mittleren Unternehmen (KMU)** in der Arbeit tendenziell unterrepräsentiert sind. Speziell für die Auswahl der Teilnehmer zur Durchführung der Experteninterviews, welche eine wichtige Grundlage für die Entwicklung des Gestaltungsansatzes einnahmen, wurde die Existenz von bereits umgesetzten ML-Anwendungen im Logistikmanagement als zusätzliches Kriterium herangezogen. Zur Bewertung des damit verbundenen Erfolges konnten jedoch lediglich qualitative Indikatoren genutzt werden, wie z. B. die erzielten Nutzenpotenziale der Anwendungen, welche jedoch erneut einer Subjektivität unterlagen. Belastbare Aussagen zum tatsächlichen Erfolg und dessen

Einordnung in einen branchenweiten Kontext konnten dadurch nicht getroffen werden. Grundsätzlich wird aber davon ausgegangen, dass sowohl in der Industrie als auch in anderen Marktsegmenten, insbesondere in Form der marktführenden Technologieunternehmen, über die Ergebnisse der vorliegenden Arbeit **hinausgehende Fortschritte zu verzeichnen** sind. Dies gilt für technische Fähigkeiten von ML, realisierbare Anwendungen und geeignete Umsetzungsmaßnahmen. In Ermangelung von branchenweiten oder -übergreifenden Vergleichen und einem eingeschränkten Zugang zu den Unternehmen konnten diese Informationen jedoch nicht berücksichtigt werden.

8.3 Ausblick

Ausgehend von der kritischen Betrachtung der erzielten Erkenntnisse bestehen mehrere Ansatzpunkte für zukünftige Forschungsarbeiten. Ein hoher Bedarf wird in der **empirischen Überprüfung** des entwickelten Gestaltungsansatzes durch dessen praktische Anwendung bei einem oder mehreren Unternehmen gesehen. Die damit verbundene Erfolgsmessung ist zudem quantitativ in Bezug auf den Nutzen und Aufwand der einzelnen Maßnahmen vorzunehmen, wofür u. a. die jeweilige Adoptionsgeschwindigkeit und die erzielten Nutzenpotenziale der ML-Anwendungen zu bewerten sind. Entsprechend der identifizierten Entwicklungen in Bezug auf die Fähigkeiten von ML und der sich verändernden Voraussetzungen im logistischen Umfeld ist die Ergebnisprüfung zudem in einem größeren zeitlichen **Abstand von mehreren Jahren zu wiederholen**, um inhaltliche Anpassungsbedarfe an den empfohlenen Maßnahmen identifizieren zu können. Neben den entwickelten Maßnahmen betrifft dies auch die weiteren Teilergebnisse der vorliegenden Arbeit in Form des Anwendungsspektrums und der Anforderungen der logistischen Praxis an den Einsatz von ML. Bei den entsprechenden Untersuchungen ist eine stärkere Einbindung von KMU sowie eine Orientierung an **Best-Practices-Ansätzen** sicherzustellen, wobei letztere anhand möglichst objektiver Kriterien auszuwählen sind, z. B. in Form bestehender Auszeichnungen oder Benchmark-Bewertungen.

Ausgehend von der vorgenommenen Generalisierung stellt ein weiterer Ansatzpunkt für zukünftige Forschungsaktivitäten die **Differenzierung der entwickelten Maßnahmen** nach verschiedenen Ausgangssituationen von Unternehmen dar, welche mittels geeigneter Kriterien zu bewerten sind. Auf dieser Grundlage sind repräsentative Szenarien festzulegen, z. B. in Form von unterschiedlichen Unternehmenstypen oder Reifegraden, und auf Basis der in der Arbeit bereitgestellten Maßnahmen szenariospezifische Ausprägungen abzuleiten. Ein zweckmäßiges Unterstützungsinstrument für die Praxis kann hierzu die Überführung der Maßnahmen in ein Bewertungstool zur Ermittlung des **unternehmensspezifischen Reifegrades** und der Ausgabe von reifegradbezogenen Maßnahmen zur Umsetzung von ML für den jeweiligen Anwender sein.

Die Notwendigkeit einer Differenzierung der Ergebnisse ist zukünftig auch für bestimmte prozessuale und technische Bereiche des in der Arbeit verwendeten Untersuchungsfeldes zu

überprüfen. Dies umfasst zum einen die dedizierte **Betrachtung von bestimmten ML-Ansätzen**, wofür sich insbesondere der bisher unterrepräsentierte, aber vielversprechende Lerntyp des Reinforcement Learning anbietet. Während hieraus auf gesamtorganisatorischer Ebene wenige Anpassungsbedarfe für die notwendigen Maßnahmen erwartet werden, ergeben sich für den Entwicklungsprozess potenzielle Veränderungen, denen u. a. in Form eines adaptierten Vorgehensmodells Rechnung zu tragen ist. In Hinblick auf den prozessualen Untersuchungsbereich wird eine **Fokussierung von einzelnen logistischen Teilsystemen** als sinnvoll erachtet, um insbesondere die realisierbaren Anwendungen, aber auch spezifische Anforderungen und Umsetzungsmaßnahmen ermitteln zu können. Hierzu wird eine Orientierung an den in dieser Arbeit identifizierten Anwendungsbereichen gemäß der ML-Typologie als zweckmäßig erachtet, z. B. in Form des Einsatzes von ML für das Supply Chain Risk Management, das Transportmanagement sowie die Produktionsplanung und -steuerung. Einen weiteren diesbezüglichen Ansatzpunkt stellt eine bewusste Auseinandersetzung mit dem bisher wenig verbreiteten Einsatz von ML für strategische Anwendungsfälle dar.

Die Betrachtung von bestimmten Teilbereichen des in der Arbeit erzielten Ergebnisspektrums ergibt sich auch für die erhobenen Anforderungen an den Technologieeinsatz, welche im Sinne ihrer interdisziplinären Ausrichtung einer hohen Detaillierungsebene bei der Entwicklung des Gestaltungsansatzes entgegengewirkt haben. Ausgehend von der Gesamtheit der identifizierten System- und Umfeldeigenschaften sind in weiteren Untersuchungen **einzelne Anforderungen zu fokussieren**, wobei dies insbesondere für die in der Arbeit hochpriorisierten Eigenschaften gilt, welche eine vergleichsweise große Bedeutung und einen geringen gegenwärtigen Umsetzungsstand aufweisen. Hierzu gehört die Entwicklung von geeigneten Strategien für die digitale Transformation von Unternehmen unter Berücksichtigung der Potenziale und Risiken von ML. Auch die technische Sicherstellung skalierbarer ML-Anwendungen zur Schließung des AI Chasm stellt einen bedeutenden Ansatzpunkt für eine dedizierte Auseinandersetzung dar. Hierzu sind Lösungsansätze zu entwickeln, die eine Berücksichtigung von Anforderungen mehrerer Anwendungsfälle bei den Entwicklungstätigkeiten sicherstellen, gleichzeitig aber auch eine wirtschaftliche Realisierung der Projekte ermöglichen. Zudem sind weitere Maßnahmen in Bezug auf die Verbesserung der Datenverfügbarkeit und -qualität für ML-Anwendungen im Logistikmanagement zu eruiieren, was Untersuchungen zur Gestaltung einer geeigneten **Data Governance** für die unternehmensweite Vorgabe von Richtlinien, Strukturen und Prozessen zum Datenumgang umfassen sollte. In diesem Zusammenhang sind auch Lösungsansätze zu verbesserten Integrationsmöglichkeiten von unternehmensexternen Daten für ML-Projekte zu entwickeln. Neben Anreizsystemen, z. B. in Form von Gain-Sharing-Ansätzen, sollte dies Untersuchungen zur Realisierung von **Datenökosystemen** für die kooperative Zusammenarbeit zwischen Wettbewerbern beim Datenaustausch beinhalten.

Ansatzpunkte für weitere Untersuchungen stehen im Zusammenhang mit bewusst in der vorliegenden Arbeit ausgeschlossenen Themenfeldern. Dies umfasst die Bewertung der **Wirtschaftlichkeit von ML-Anwendungen**, welche aktuell von vielen Unternehmen infolge der

teils schwer quantifizierbaren Erfolge, z. B. in Form der Verbesserung der Transparenz oder Entscheidungsqualität, als Herausforderung angesehen wird. Um zukünftig belastbare Aussagen für die Erstellung von Business Cases zur Umsetzung von ML-Anwendungen treffen zu können, bedarf es durch weitere Forschungsarbeiten einer Entwicklung von geeigneten Berechnungslogiken und Methoden zur Erfolgsmessung. Neben den betriebswirtschaftlichen Effekten aus dem Einsatz der Anwendungen umfasst dies auch eine Quantifizierung des Aufwands für die Umsetzung der benötigten Maßnahmen. In diesem Zusammenhang wird auch eine stärkere wissenschaftliche Auseinandersetzung mit den Vor- und Nachteilen einer Eigen- oder Fremdentwicklung von ML-Anwendungen (Build-or-Buy) als sinnvoll erachtet, die in einer Entscheidungslogik für die Praxis münden sollte. Ein weiteres bewusst exkludiertes Themenfeld betrifft **ethische und rechtliche Fragestellungen** zum Einsatz von ML-Anwendungen im Logistikmanagement, z. B. in Form der Zulässigkeit und etwaiger Grenzen für die Übergabe von Entscheidungsumfängen an Systeme sowie die damit verbundene Verantwortung für fehlerhafte Ergebnisse. Hierzu bedarf es u. a. einer Differenzierung von Entscheidungen bzw. Anwendungsfällen entsprechend individueller Anforderungen, z. B. in Bezug auf die sozialen Auswirkungen, wofür auch aktuelle und zukünftige Restriktionen seitens des Gesetzgebers zu berücksichtigen sind. Entsprechend der bereichs- bzw. domänenübergreifenden Bedarfe sind die damit verbundenen Untersuchungen jedoch nicht auf die Logistik zu beschränken, sondern im Rahmen gesamtgesellschaftlicher Betrachtungen durchzuführen.

Anhang

Literature Reviews mit Schnittmengen zum Untersuchungsfeld

Autor	Titel	Technologie	Logistik	Me- thode	Rele- vanz
Agarwal, Jayant (2019)	Application of Machine Learning Techniques in Supply Chain Management	ML, inkl. NLP	Gesamt	S	++
Baryannis et al. (2019b)	Supply chain risk management and artificial intelligence: state of the art and future research directions	KI, inkl. ML	SCRM	S	+
Bousqaoui et al. (2017)	Machine Learning applications in supply chains: an emphasis on neural network applications	ML, v. a. KNN, ohne RL	Wenig Produktion	S	+
Ni et al. (2019)	A systematic review of the research trends of machine learning in supply chain management	ML ohne RL	Gesamt	S	++
Giri et al. (2019)	A detailed review of artificial intelligence applied in the fashion and apparel industry	KI mit ML und GA	Textil Supply Chains	S	++
Hellingrath, Lechtenberg (2019)	Applications of Artificial Intelligence in SCM and Logistics: focusing Onto Recognition for Supply Chain Execution	KI, inkl. ML, für Recognition	Ausführung	S	+
Herden, Bunzel (2018)	Archetypes of Supply Chain Analytics	Data Analytics	Wenig Produktion	E	+
Konovalenko, Ludwig (2019)	Event processing in supply chain management	Event Processing	Gesamt	S	o
Krauß et al. (2019)	Maschinelles Lernen in der Produktion	ML	Nur Produktion	E	+
Lima-Junior, Carpinetti (2017)	Quantitative models for supply chain performance evaluation: a literature review	Diverse Methoden, inkl. KI ohne RL	SCRM	S	o
Min (2010)	Artificial intelligence in supply chain management: theory and applications	KI, inkl. ML, MAS und GA	Ohne Produktion	E	o
Ngai et al. (2014)	Decision support and intelligent systems in the textile and apparel supply chain: an academic review of research articles	KI, inkl. KNN und GA, ohne RL	Textil Supply Chains	S	o
Peidro et al. (2009)	Quantitative models for supply chain planning under uncertainty: a review	Diverse Methoden, inkl. KI	Unsicherheiten in Planung	S	o
Sharma et al. (2020)	A Systematic Literature Review on ML Applications for Sustainable Agriculture Supply Chain Performance	ML	Agriculture Supply Chains	S	++
Wang et al. (2018a)	Deep Learning for Smart Manufacturing: Methods and Applications	DL für Anomaly Detection	Nur Produktion	E	+
Wenzel et al. (2019)	A Literature Review on Machine Learning in Supply Chain Management	ML	Ohne Produktion	S	+

Legende: Anzahl relevanter Artikel für vorliegende Arbeit: ++ = „viele“ + = „vereinzelte“ o = „wenige“
 Methode: S = systematische Literaturanalyse E = explorative Literaturanalyse

Tabelle 33: Übersichtsarbeiten mit Schnittmengen zum Untersuchungsfeld

Bibliografische Daten der Artikel zu ML-Anwendungen im Logistikmanagement

Die im Rahmen der systematischen Literaturanalyse 112 identifizierten Artikel mit Informationen zu ML-Anwendungen im Logistikmanagement verteilen sich auf 70 verschiedene Publikationsorgane, welche größtenteils der Informatik und der Produktion zuzuordnen sind. Die in Abbildung 99 dargestellten Publikationsorgane weisen mindestens drei Artikel auf.

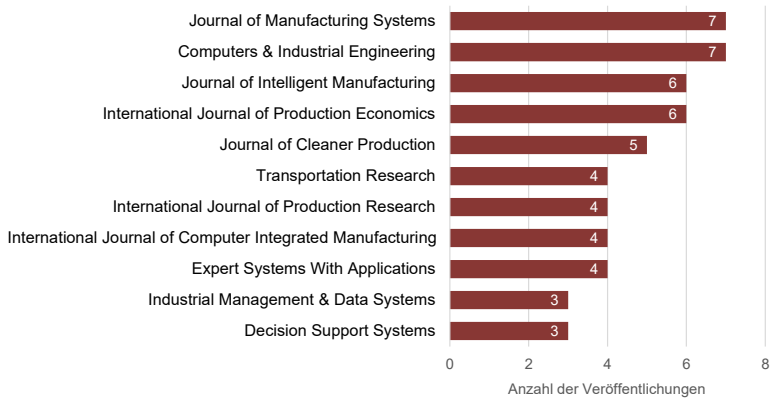


Abbildung 99: Bibliografische Auswertung der Datenbasis – Publikationsorgane⁷²⁰

Die Artikel wurden in 31 Ländern aus sechs Kontinenten publiziert. Die veröffentlichungsstärksten Länder mit mindestens drei Artikeln sind in Abbildung 100 dargestellt. China weist mit über ein Fünftel der Artikel die größte Anzahl auf. Auf dem zweiten Rang folgen die USA mit ca. 10 % der Artikel. Deutschland nimmt mit ca. 5 % der Artikel hinter Indien, Iran und Großbritannien den fünften Rang ein.




Abbildung 100: Bibliografische Auswertung der Datenbasis – Land der Publikation⁷²¹

⁷²⁰ Eigene Darstellung

⁷²¹ Eigene Darstellung

In Abbildung 101 ist die Verteilung der Artikel im Betrachtungszeitraum 2012 bis 2020 dargestellt. Seit 2016 lässt sich ein starker Anstieg verzeichnen. Dies beinhaltet auch eine Zunahme von neuen Lernverfahren, die zuvor wenig präsent waren. Demnach findet sich bspw. ein Großteil der Veröffentlichungen mit ML-Anwendungen auf Grundlage des Reinforcement Learning in den letzten drei Jahren. Das Jahr 2020 wurde entsprechend des Zeitpunktes des Suchprozesses nicht gesamthafth berücksichtigt.




Abbildung 101: Bibliografische Auswertung der Datenbasis – Jahr der Publikation⁷²²

⁷²² Eigene Darstellung

Merkmale der ML-Anwendungen als Eingangsvariablen für Clusteranalyse

Typenart	Merkmal	Merkmalsausprägung (Variable)	Nr.
Problemlösungsfähigkeit	Lernaufgabe	Klassifikation	T-01
		Regression	T-02
		Gruppierung	T-03
		Ausreißerererkennung	T-04
		Optimierung	T-05
	Lernverfahren	KNN	T-06
		Sonstige NN	T-07
		SVM	T-08
		Entscheidungsbaumbasierte Verfahren	T-09
		Evolutionäre Algorithmen	T-10
		Klassische statistische Verfahren	T-11
		Bayes Verfahren	T-12
		Sonstige Verfahren	T-13
	Art der eingebundenen Daten	Numerische Daten	T-14
		Komplexe Daten	T-15
	Zeitliche Bereitstellung des Outputs	Batch	T-16
		Real-Time	T-17
	Interaktion mit anderen Technologien	Eigenständige Anwendung	T-18
		Eingebettete Anwendung	T-19
	Datenanalytische Zielsetzung	Descriptive	T-20
		Predictive	T-21
		Prescriptive	T-22
Logistischer Anwendungsbereich	Logistische Aufgabenart	Strategische Planung	P-01
		Taktische Planung	P-02
		Operative Planung (Steuerung)	P-03
		Überwachung (Kontrolle)	P-04
	Prozessübergreifender Charakter	Eigenständiger Prozess	P-05
		Übergreifender Prozess	P-06
	Akteursschnittstelle	Keine Schnittstellen (unternehmensintern)	P-07
		Vertikale Schnittstelle Hersteller-Zulieferer	P-08
		Vertikale Schnittstelle Hersteller-Kunde	P-09
		Laterale Schnittstelle	P-10
	Logistikfluss	Materialfluss	P-11
		Informationsfluss	P-12
	Betrachtungsobjekt	Materialien und Produkte	P-13
		Maschinen und Anlagen	P-14
		Subjekte	P-15
		Objekte	P-16
		Informationen und Daten	P-17

Logistische Zielsetzung	Kosten	P-18
	Zeit	P-19
	Qualität	P-20
	Flexibilität	P-21
	Robustheit	P-22
	Nachhaltigkeit	P-23
	Informationstransparenz	P-24
Leistungsziele	Anzahl und Menge	P-25
	Länge und Zeiten	P-26
	Nutzungsgrad und Leistung	P-27
Qualitätsziele	Lieferfähigkeit und Lieferbereitschaft	P-28
	Termintreue und Lieferzuverlässigkeit	P-29
	Sendungsqualität	P-30
Bisherige Ausführung	Manuell umgesetzt	P-31
	Nicht vorhanden	P-32

Tabelle 34: Merkmale der ML-Anwendungen für Clusteranalyse

Zuordnung der Veröffentlichungen zu ML-Typologie

	Identifikation	Analyse und Bewertung	Prognose I	Prognose II	Optimierung
Langfristige Beschaffungs- und Absatzplanung			Puchalsky et al. (2018)	Mori et al. (2012); Fallahpour et al. (2017); Gupta, Pathak (2014); Martinez et al. (2020)	
Bedarfs- und Kapazitätsmanagement		Lolli et al. (2019)	Sustrova (2016); Tian et al. (2013); Abbasi et al. (2020); Inprasit, Tanachutiwat (2018); Lau et al. (2013); Yang, Sutrisno (2018); Karaoglan, Karademir (2017)	Singh, Soni (2019); Santis et al. (2017); Cheng, Tang (2018); Ning et al. (2020); Clercq et al. (2019); Ren et al. (2020)	
Lieferantenmanagement		Hosseini, Khaled (2019); González-Cancelas et al. (2019); Ghorbani et al. (2012)	Mortazavi et al. (2015); Gürbüz et al. (2019); Lima-Junior, Carpinetti (2019); Silva et al. (2017)		Cavalcante et al. (2019); Sun, Zhao (2012)
Produktionsplanung und -steuerung	Wang et al. (2018c); Zhang, Jiang (2020)	Lv et al. (2018); Rokach, Hutter (2012)	Luo et al. (2015); Brunelli et al. (2019)	Worapradya, Thanakijkasem (2015); Liu et al. (2018); Lingitz et al. (2018); Wang et al. (2018b)	Zhang et al. (2014); Wang et al. (2017a); Nasiri et al. (2017); Yin et al. (2020); Doltsinis et al. (2014); Zheng et al. (2019); Li et al. (2012)
Transportmanagement	Di Ciccio et al. (2016)			Bhattacharya et al. (2014); Maghrebi et al. (2015); Owczarek, Janke (2018)	Irannezhad et al. (2020); Cao et al. (2020); Becker et al. (2016)
Prozessmonitoring	Ma et al. (2018); Joshi et al. (2020); Wen et al. (2019); Carvajal Soto et al. (2019); Kucukoglu et al. (2018)		Singh et al. (2012); Papananias et al. (2019); Wang et al. (2017b); Wang et al. (2012)		
Supply Chain Risk und Performance Management		Ye et al. (2015); Zage et al. (2013); Hiromoto et al. (2017); Tran et al. (2019)	Lima-Junior, Carpinetti (2020)	Liu et al. (2016); Ko et al. (2017); Baryannis et al. (2019a)	

Tabelle 35: ML-Typologie mit repräsentativen Anwendungsfällen⁷²³

⁷²³ Es handelt es sich um die bei der Charakterisierung der Typen in Kapitel 5.2 genutzten Artikel.

Literaturverzeichnis

- Abbasi, B.; Babaei, T.; Hosseinifard, Z.; Smith-Miles, K.; Dehghani, M. (2020): Predicting solutions of large-scale optimization problems via machine learning: A case study in blood supply chain management. In: *Computers & Operations Research* 119, S. 1–20.
- Acatech (2019): Auf dem Weg zu einem intelligenten Mobilitätsraum. Deutsche Akademie der Technikwissenschaften e.V. München.
- Acatech (2021): Lernende Systeme. Glossar. Deutsche Akademie der Technikwissenschaften e.V. Online verfügbar unter <https://www.plattform-lernende-systeme.de/glossar.html>, zuletzt geprüft am 15.09.2022.
- Adam, D. (1993): Planung und Entscheidung. Wiesbaden: Gabler Verlag.
- Agarwal, A.; Jayant, A. (2019): Applications of Machine Learning Techniques in Supply Chain Management. In: *International Research Journal of Management Science & Technology* 10 (6), S. 29–49.
- Akkiraju, R.; Sinha, V.; Xu, A.; Mahmud, J.; Gundecha, P.; Liu, Z. et al. (2020): Characterizing Machine Learning Processes: A Maturity Framework. In: Fahland, D.; Ghidini, C.; Becker, J. und Dumas, M. (Hrsg.): *Business Process Management*. Cham: Springer International Publishing, S. 17–31.
- Alpaydin, E. (2010): Introduction to machine learning. Cambridge, Massachusetts: MIT Press.
- Amershi, S.; Begel, A.; Bird, C.; DeLine, R.; Gall, H.; Kamar, E. et al. (2019): Software Engineering for Machine Learning: A Case Study. In: *IEEE/ACM 41st International Conference on Software Engineering: Software Engineering in Practice (ICSE-SEIP)*, S. 291–300.
- Arnold, D.; Isermann, H.; Kuhn, A.; Tempelmeier, H.; Furmans, K. (2008): *Handbuch Logistik*. Berlin, Heidelberg: Springer.
- Arnott, D.; Pervan, G. (2015): A critical analysis of decision support systems research. In: Willcocks, L. P.; Sauer, C. und Lacity, M. C. (Hrsg.): *Formulating Research Methods for Information Systems*. London: Palgrave Macmillan, S. 127–168.
- Backhaus, K.; Erichson, B.; Plinke, W.; Weiber, R. (2016): *Multivariate Analysemethoden*. Berlin, Heidelberg: Springer Gabler.
- Baker, J. (2012): The Technology–Organization–Environment Framework. In: Dwivedi, Y. K.; Wade, M. R. und Schneberger, S. L. (Hrsg.): *Information Systems Theory*. New York: Springer, S. 231–245.
- Balzert, H. (2009): *Lehrbuch der Softwaretechnik: Basiskonzepte und Requirements Engineering*. Heidelberg: Spektrum Akademischer Verlag.
- Bamberg, G.; Coenenberg, A. G.; Krapp, M. (2012): *Betriebswirtschaftliche Entscheidungslehre*. München: Verlag Franz Vahlen.
- Barney, J. (1991): Firm Resources and Sustained Competitive Advantage. In: *Journal of Management* 17 (1), S. 99–120.
- Barney, J. B. (2001): Resource-based theories of competitive advantage: A ten-year retrospective on the resource-based view. In: *Journal of Management* 27 (6), S. 643–650.
- Barreto, I. (2010): Dynamic Capabilities: A Review of Past Research and an Agenda for the Future. In: *Journal of Management* 36 (1), S. 256–280.
- Baryannis, G.; Dani, S.; Antoniou, G. (2019a): Predicting supply chain risks using machine learning: The trade-off between performance and interpretability. In: *Future Generation Computer Systems* 101, S. 993–1004.
- Baryannis, G.; Validi, S.; Dani, S.; Antoniou, G. (2019b): Supply chain risk management and artificial intelligence: state of the art and future research directions. In: *International Journal of Production Research* 57 (7), S. 2179–2202.

-
- Bauchhage, C.; Brito, E.; Daase, I.; Franken, L.; Georgiev, B.; Hecker, D. et al. (2020): Quantum Machine Learning. Eine Analyse zu Kompetenz, Forschung und Anwendung. Fraunhofer-Allianz Big Data und Künstliche Intelligenz. Sankt Augustin.
- Beck, K.; Beedle, M.; van Bennekum, A.; Cockburn, A.; Cunningham, W.; Fowler, M. et al. (2001): Manifesto for Agile Software Development. Online verfügbar unter <https://agilemanifesto.org/>, zuletzt geprüft am 15.09.2022.
- Becker, T.; Illigen, C.; McKelvey, B.; Hülsmann, M.; Windt, K. (2016): Using an agent-based neural-network computational model to improve product routing in a logistics facility. In: International Journal of Production Economics 174, S. 156–167.
- Beer, J. M.; Fisk, A. D.; Rogers, W. A. (2014): Toward a framework for levels of robot autonomy in human-robot interaction. In: Journal of human-robot interaction 3 (2), S. 74–99.
- Beierle, C.; Kern-Isberner, G. (2019): Methoden wissensbasierter Systeme. Wiesbaden: Springer Fachmedien Wiesbaden.
- Bellman, R. E. (1966): Adaptive Control Processes. Princeton, NJ: Princeton University Press.
- Bhattacharya, A.; Kumar, S. A.; Tiwari, M.; Talluri, S. (2014): An intermodal freight transport system for optimal supply chain logistics. In: Transportation Research Part C: Emerging Technologies 38, S. 73–84.
- Biamonte, J.; Wittek, P.; Pancotti, N.; Rebentrost, P.; Wiebe, N.; Lloyd, S. (2017): Quantum machine learning. In: Nature 549 (7671), S. 195–202.
- Binder, V. A.; Kantowsky, J. (1996): Technologiepotentiale. Wiesbaden: Deutscher Universitätsverlag.
- Bitkom; DFKI (2017): Entscheidungsunterstützung mit Künstlicher Intelligenz. Wirtschaftliche Bedeutung, gesellschaftliche Herausforderungen, menschliche Verantwortung. Bitkom e. V.; Deutsches Forschungszentrum für Künstliche Intelligenz GmbH. Berlin.
- BMDV (2020): SELECT - Smarte Entscheidungsassistenz für Logistikketten der Binnenschifffahrt durch ETA-Prognosen. Bundesministerium für Digitales und Verkehr. Online verfügbar unter https://www.innovativehafentechnologien.de/wp-content/uploads/2020/03/IHATEC_Projektsteckbrief_SELECT_formatiert_2020-03-13_ma-Anhang3.pdf, zuletzt geprüft am 15.09.2022.
- BMVI (2017): SMECS - Smart Event Forecast for Seaports. Bundesministerium für Verkehr und digitale Infrastruktur. Online verfügbar unter https://www.innovativehafentechnologien.de/wp-content/uploads/2017/09/IHATEC_Projektsteckbrief_SMECS_formatiert.pdf, zuletzt geprüft am 15.09.2022.
- BMWI (2019): Technologieszenario „Künstliche Intelligenz in der Industrie 4.0“. Bundesministerium für Wirtschaft und Energie. Berlin.
- BMWI (2020): Einsatz von Künstlicher Intelligenz in der Deutschen Wirtschaft. Bundesministerium für Wirtschaft und Energie. Berlin.
- Bortz, J.; Döring, N. (2006): Forschungsmethoden und Evaluation. Berlin: Springer.
- Bostrom, N. (2014): Superintelligence. Oxford: Oxford University Press.
- Bostrom, N.; Yudkowsky, E. (2014): The ethics of artificial intelligence. In: Frankish, K.; Ramsey, W. M. und Ramsey, W. (Hrsg.): The Cambridge handbook of artificial intelligence. Cambridge: Cambridge Univ. Press, S. 316–334.
- Böttcher, B.; Klemm, D.; Velten, C. (2017): Machine Learning im Unternehmenseinsatz. Crisp Research AG.
- Bottou, L. (2010): Large-Scale Machine Learning with Stochastic Gradient Descent. In: Lechevallier, Y. und Saporta, G. (Hrsg.): Proceedings of COMPSTAT'2010. Berlin, Heidelberg: Physica-Verlag, S. 177–186.
- Bousqaoui, H.; Achchab, S.; Tikito, K. (2017): Machine learning applications in supply chains: An emphasis on neural network applications. In: 3rd International Conference of Cloud Computing Technologies and Applications (CloudTech). IEEE, S. 1–7.
- Braunschmidt, I.; Hauschild, J. (2005): Technologieinduzierte Innovationen. Wiesbaden: Deutscher Universitätsverlag.

-
- Breck, E.; Cai, S.; Nielsen, E.; Salib, M.; Sculley, D. (2017): The ML test score: A rubric for ML production readiness and technical debt reduction. In: IEEE International Conference on Big Data. IEEE, S. 1123–1132.
- Bretzke, W.-R. (1980): Der Problembezug von Entscheidungsmodellen. Tübingen: Mohr.
- Briskorn, D. (2020): Operations Research. Berlin: Springer Gabler.
- Brunelli, L.; Masiero, C.; Tosato, D.; Beghi, A.; Susto, G. A. (2019): Deep Learning-based Production Forecasting in Manufacturing: a Packaging Equipment Case Study. In: Procedia Manufacturing 38, S. 248–255.
- Bughin, J.; Hazan, E.; Ramaswamy, S.; Chui, M.; Allas, T.; Dahlstrom, P. et al. (2017): Artificial intelligence: the next digital frontier? McKinsey & Company.
- Bullinger, H.-J. (1994): Einführung in das Technologiemanagement. Wiesbaden: Vieweg+Teubner Verlag.
- Busse, A.; Gerlach, B.; Lengeling, J. C.; Poschmann, P.; Werner, J.; Zarnitz, S. (2021): Towards Digital Twins of Multimodal Supply Chains. In: Logistics 5 (2), S. 25.
- Buxmann, P.; Schmidt, H. (2019): Künstliche Intelligenz. Berlin, Heidelberg: Springer.
- BVL (2010): Positionspapier zum Grundverständnis der Logistik als wissenschaftliche Disziplin. Bundesvereinigung Logistik (BVL) e. V.
- BVL (2018): Stimmungsbarometer zur künstlichen Intelligenz in der Logistik. Bundesvereinigung Logistik (BVL) e. V. Bremen.
- Cao, Z.; Guo, H.; Song, W.; Gao, K.; Chen, Z.; Le Zhang; Zhang, X. (2020): Using Reinforcement Learning to Minimize the Probability of Delay Occurrence in Transportation. In: IEEE Transactions on Vehicular Technology 69 (3), S. 2424–2436.
- Carbonell, J. G.; Michalski, R. S.; Mitchell, T. M. (1983): An Overview of Machine Learning. In: Michalski, R. S.; Carbonell, J. G. und Mitchell, T. M. (Hrsg.): Machine Learning. Berlin, Heidelberg: Springer, S. 3–24.
- Carvajal Soto, J. A.; Tavakolizadeh, F.; Gyulai, D. (2019): An online machine learning framework for early detection of product failures in an Industry 4.0 context. In: International Journal of Computer Integrated Manufacturing 32 (4-5), S. 452–465.
- Cavalcante, I. M.; Frazzon, E. M.; Forcellini, F. A.; Ivanov, D. (2019): A supervised machine learning approach to data-driven simulation of resilient supplier selection in digital manufacturing. In: International Journal of Information Management 49, S. 86–97.
- Chapelle, O.; Schölkopf, B.; Zien, A. (2006): Semi-supervised learning. Cambridge, Massachusetts: MIT Press.
- Chapman, P.; Clinton, J.; Kerber, R.; Khabaza, T.; Reinartz, T.; Shearer, C.; Wirth, R. (2000): CRISP-DM 1.0.
- Cheng, C.; Tang, L. (2018): Robust policies for a multi-stage production/inventory problem with switching costs and uncertain demand. In: International Journal of Production Research 56 (12), S. 4264–4282.
- Chmielewicz, K. (1994): Forschungskonzeptionen der Wirtschaftswissenschaft. Stuttgart: Schäffer-Pöschel.
- Clercq, D. de; Jalota, D.; Shang, R.; Ni, K.; Zhang, Z.; Khan, A. et al. (2019): Machine learning powered software for accurate prediction of biogas production: A case study on industrial-scale Chinese production data. In: Journal of Cleaner Production 218, S. 390–399.
- Conboy, K.; Carroll, N. (2019): Implementing Large-Scale Agile Frameworks: Challenges and Recommendations. In: IEEE Software 36 (2), S. 44–50.
- CrowdFlower (2016): Data Science Report. Online verfügbar unter https://visit.figure-eight.com/rs/416-ZBE-142/images/CrowdFlower_DataScienceReport_2016.pdf, zuletzt geprüft am 15.09.2022.
- Das, S. K. (2014): Computational business analytics. Boca Raton, Fla.: CRC Press.
- Dastin, J. (2018): Amazon scraps secret AI recruiting tool that showed bias against women. Reuters. Online verfügbar unter <https://www.reuters.com/article/us-amazon-com-jobs-automation-insight/>

amazon-scrapes-secret-ai-recruiting-tool-that-showed-bias-against-women-idUSKCN1MK08G, zuletzt geprüft am 15.09.2022.

- Davenport, T. H.; Harris, J. G. (2017): *Competing on analytics*. Boston, Massachusetts: Harvard Business School Press.
- Davis, F. D. (1989): Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology. In: *MIS Quarterly* 13 (3), S. 319–340.
- DePietro, R.; Wiarda, E.; Fleisher, M. (1990): The context for change: Organization, technology and environment. In: Tornatzky, L. G. und Fleischer, M. (Hrsg.): *The processes of technological innovation*. Lexington, Massachusetts: Lexington Books, S. 151–175.
- Deutsche Bundesregierung (2018): *Strategie Künstliche Intelligenz der Bundesregierung*. Berlin.
- Deutscher Bundestag (2020): *Strategie Künstliche Intelligenz der Bundesregierung – Fortschreibung 2020*. Berlin.
- Di Ciccio, C.; van der Aa, H.; Cabanillas, C.; Mendling, J.; Prescher, J. (2016): Detecting flight trajectory anomalies and predicting diversions in freight transportation. In: *Decision Support Systems* 88, S. 1–17.
- Dietvorst, B. J.; Simmons, J. P.; Massey, C. (2015): Algorithm aversion: people erroneously avoid algorithms after seeing them err. In: *Journal of experimental psychology* 144 (1), S. 114–126.
- Dillmann, R. (1988): *Lernende Roboter*. Berlin, Heidelberg: Springer.
- Döbel, I.; Leis, M.; Vogelsang, M. M.; Neustroev, D.; Petzka, H.; Rüping, S. et al. (2018): *Maschinelles Lernen - Kompetenzen, Anwendungen und Forschungsbedarf*. Fraunhofer-Gesellschaft. München.
- Doltsinis, S.; Ferreira, P.; Lohse, N. (2014): An MDP Model-Based Reinforcement Learning Approach for Production Station Ramp-Up Optimization: Q-Learning Analysis. In: *IEEE Transactions on Systems, Man, and Cybernetics: Systems* 44 (9), S. 1125–1138.
- Dörner, D. (1979): *Problemlösen als Informationsverarbeitung*. Stuttgart: Kohlhammer.
- Dregger, J.; Niehaus, J.; Itermann, P.; Hirsch-Kreinsen, H.; Hompel, M. ten (2016): The digitization of manufacturing and its societal challenges: a framework for the future of industrial labor. In: *IEEE International Symposium on Ethics in Engineering, Science and Technology (ETHICS)*. Piscataway, NJ: IEEE, S. 1–3.
- Duden (2021): *Intelligenz*. Bibliographisches Institut GmbH. Online verfügbar unter <https://www.duden.de/rechtschreibung/Intelligenz>, zuletzt geprüft am 15.09.2022.
- Dunn, J. C. (1973): A Fuzzy Relative of the ISODATA Process and Its Use in Detecting Compact Well-Separated Clusters. In: *Journal of Cybernetics* 3 (3), S. 32–57.
- Eckstein, P. P. (2014): *Statistik für Wirtschaftswissenschaftler*. Wiesbaden: Springer Fachmedien Wiesbaden.
- Europäische Kommission (2018): *A definition of AI: main capabilities and disciplines*. European Commission, Directorate-General for Communication.
- Europäische Kommission (2019): *Ethics guidelines for trustworthy AI*. European Commission, Directorate-General for Communication.
- Everitt, B. (2011): *Cluster analysis*. Chichester: Wiley.
- Fahrmeir, L.; Kneib, T.; Lang, S. (2009): *Regression*. Berlin, Heidelberg: Springer.
- Fallahpour, A.; Wong, K. Y.; Olugu, E. U.; Musa, S. N. (2017): A Predictive Integrated Genetic-Based Model for Supplier Evaluation and Selection. In: *International Journal of Fuzzy Systems* 19 (4), S. 1041–1057.
- Fayyad, U.; Piataesky-Shapiro, G.; Smyth, P. (1996): From Data Mining to Knowledge Discovery in Databases. In: *AI Magazine* 17 (3), S. 37–54.
- Fleischmann, B.; Meyr, H.; Wagner, M. (2005): *Advanced Planning*. In: Stadler, H. und Kilger, C. (Hrsg.): *Supply Chain Management and Advanced Planning*. Berlin, Heidelberg: Springer, S. 81–108.

-
- Flick, U.; Kardoff, E. v.; Steinke, I. (2010): Was ist qualitative Forschung? Einleitung und Überblick. In: Flick, U.; Kardoff, E. v. und Steinke, I. (Hrsg.): *Qualitative Forschung*. Reinbek bei Hamburg: rowohlt's enzyklopädie im Rowohlt Taschenbuch Verlag, S. 13–29.
- Forza, C. (2002): Survey research in operations management: a process-based perspective. In: *International Journal of Operations & Production Management* 22 (2), S. 152–194.
- Fouse, S.; Cross, S.; Lapin, Z. (2020): DARPA's Impact on Artificial Intelligence. In: *AI Magazine* 41 (2), S. 3–8.
- Frankish, K.; Ramsey, W. M. (2014): Introduction. In: Frankish, K.; Ramsey, W. M. und Ramsey, W. (Hrsg.): *The Cambridge handbook of artificial intelligence*. Cambridge: Cambridge Univ. Press, S. 1–12.
- Franklin, S. (2014): History, motivations, and core themes. In: Frankish, K.; Ramsey, W. M. und Ramsey, W. (Hrsg.): *The Cambridge handbook of artificial intelligence*. Cambridge: Cambridge Univ. Press, S. 15–33.
- Franklin, S.; Graesser, A. (1997): Is It an agent, or just a program?: A taxonomy for autonomous agents. In: Carbonell, J. G.; Siekmann, J.; Goos, G. et al. (Hrsg.): *Intelligent Agents III*. Berlin, Heidelberg: Springer, S. 21–35.
- Freiling, J. (2004): A Competence-based Theory of the Firm. In: *Management Revue* 15 (1), S. 27–52.
- Funke, J. (2003): *Problemlösendes Denken*. Stuttgart: Kohlhammer.
- Fuster, J. M. (2005): *Cortex and Mind*. Cary: Oxford University Press Incorporated.
- Gerlach, B.; Zarnitz, S.; Nitsche, B.; Straube, F. (2021): Digital Supply Chain Twins - Conceptual Clarification, Use Cases and Benefits. In: *Logistics* 5 (4), S. 86.
- Gerpott, T. J. (1999): *Strategisches Technologie- und Innovationsmanagement*. Stuttgart: Schäffer-Poeschel.
- Ghorbani, M.; Arabzad, S. M.; Bahrami, M. (2012): Applying a Neural Network algorithm to Distributor selection problem. In: *Procedia - Social and Behavioral Sciences* 41, S. 498–505.
- Gil, Y.; Selman, B. (2019): A 20-Year Community Roadmap for Artificial Intelligence Research in the US. Computing Community Consortium (CCC) and Association for the Advancement of Artificial Intelligence (AAAI). Online verfügbar unter <https://arxiv.org/pdf/1908.02624>, zuletzt geprüft am 15.09.2022.
- Giri, C.; Jain, S.; Zeng, X.; Bruniaux, P. (2019): A Detailed Review of Artificial Intelligence Applied in the Fashion and Apparel Industry. In: *IEEE Access* 7, S. 95376–95396.
- Gläß, R. (2018): *Künstliche Intelligenz im Handel 1 – Überblick*. Wiesbaden: Springer Fachmedien Wiesbaden.
- Goertzel, B. (2007): Human-level artificial general intelligence and the possibility of a technological singularity: A reaction to Ray Kurzweil's *The Singularity Is Near*, and McDermott's critique of Kurzweil. In: *Artificial Intelligence* 171 (18), S. 1161–1173.
- González-Cancelas, N.; Serrano, B. M.; Soler-Flores, F. (2019): Seaport Sustainable: Use of Artificial Intelligence to Evaluate Liquid Natural Gas Utilization in Short Sea Shipping. In: *Transportation Journal* 58 (3), S. 197–221.
- Good, I. J. (1966): Speculations Concerning the First Ultraintelligent Machine. In: *Advances in Computers*. Volume 6. Elsevier, S. 31–88.
- Goodfellow, I. J.; Pouget-Abadie, J.; Mirza, M.; Xu, B.; Warde-Farley, D.; Ozair, S. et al. (2014): Generative Adversarial Networks. Online verfügbar unter <https://arxiv.org/pdf/1406.2661>, zuletzt geprüft am 15.09.2022.
- Goodhue, D. L.; Thompson, R. L. (1995): Task-Technology Fit and Individual Performance. In: *MIS Quarterly* 19 (2), S. 213–236.
- Gottschalk-Mazouz, N. (2019): Autonomie. In: Liggieri, K. und Müller, O. (Hrsg.): *Mensch-Maschine-Interaktion*. Stuttgart: J.B. Metzler, S. 238–240.
- Gudehus, T. (2010): *Logistik*. Berlin: Springer.

-
- Gupta, A.; Maranas, C. D. (2003): Managing demand uncertainty in supply chain planning. In: *Computers & Chemical Engineering* 27 (8-9), S. 1219–1227.
- Gupta, R.; Pathak, C. (2014): A Machine Learning Framework for Predicting Purchase by Online Customers based on Dynamic Pricing. In: *Procedia Computer Science* 36, S. 599–605.
- Gürbüz, F.; Eski, İ.; Denizhan, B.; Dağlı, C. (2019): Prediction of damage parameters of a 3PL company via data mining and neural networks. In: *Journal of Intelligent Manufacturing* 30 (3), S. 1437–1449.
- Haag, C.; Schuh, G.; Kreysa, J.; Schmelter, K. (2011): Technologiebewertung. In: Schuh, G. und Klappert, S. (Hrsg.): *Technologiemanagement*. Berlin, Heidelberg: Springer, S. 309–366.
- Halkidi, M.; Batistakis, Y.; Vazirgiannis, M. (2001): On Clustering Validation Techniques. In: *Journal of Intelligent Information Systems* 17 (2-3), S. 107–145.
- Han, J.; Pei, J.; Kamber, M. (2011): *Data Mining: Concepts and Techniques*: Elsevier Science.
- Handfield, R.; Straube, F.; Pfohl, H.-C.; Wieland, A. (2013): Vorteile im Wettbewerb durch Beherrschung von Komplexität. Hamburg: DVV Media Group.
- Hansen, H. R.; Mendling, J.; Neumann, G. (2019): *Wirtschaftsinformatik*. Berlin, Boston: De Gruyter.
- Harnad, S. (1991): Other bodies, other minds: A machine incarnation of an old philosophical problem. In: *Minds and Machines* (1), S. 43–54.
- Harvard Business School (2016): *Harvard Business Report - Review The Next Analytics Age: Machine Learning*: Harvard Business School Publishing Cooperation.
- Hastie, T.; Tibshirani, R.; Friedman, J. (2009): *The Elements of Statistical Learning*. New York: Springer.
- Hau, M. (2016): *Cognitive Organisation*. Berlin: Springer Vieweg.
- He, X.; Zhao, K.; Chu, X. (2019): AutoML: A Survey of the State-of-the-Art. Online verfügbar unter <https://arxiv.org/pdf/1908.00709>, zuletzt geprüft am 15.09.2022.
- Hellingrath, B.; Lechtenberg, S. (2019): Applications of Artificial Intelligence in Supply Chain Management and Logistics: Focusing Onto Recognition for Supply Chain Execution. In: Bergener, K.; Räckers, M. und Stein, A. (Hrsg.): *The Art of Structuring*. Cham: Springer International Publishing, S. 283–296.
- Herden, T.; Bunzel, S. (2018): Archetypes of Supply Chain Analytics Initiatives - An Exploratory Study. In: *Logistics* 2 (2), S. 1–20.
- Heßler, M. (2019): Automation/Automatisierung. In: Liggieri, K. und Müller, O. (Hrsg.): *Mensch-Maschine-Interaktion*. Stuttgart: J.B. Metzler, S. 235–237.
- Hiro moto, R. E.; Haney, M.; Vakanski, A. (2017): A secure architecture for IoT with supply chain risk management. In: 9th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS). IEEE, S. 431–435.
- Hirsch-Kreinsen, H.; Ittermann, P. (2021): Digitalization of Work Processes: A Framework for Human-Oriented Work Design. In: McMurray, A. J.; Muenjohn, N. und Weerakoon, C. (Hrsg.): *The Palgrave handbook of workplace innovation*. Cham: Palgrave Macmillan, S. 273–293.
- Holsapple, C.; Lee-Post, A.; Pakath, R. (2014): A unified foundation for business analytics. In: *Decision Support Systems* 64, S. 130–141.
- Hopf, C. (2010): Qualitative Interviews - ein Überblick. In: Flick, U.; Kardorff, E. v. und Steinke, I. (Hrsg.): *Qualitative Forschung*. Reinbek bei Hamburg: rowohits enzyklopädie im Rowohlt Taschenbuch Verlag, S. 349–360.
- Hoppe, T. (1996): Kriterien zur Auswahl maschineller Lernverfahren. In: *Informatik-Spektrum* 19 (1), S. 12–19.
- Hosseini, S.; Khaled, A. A. (2019): A hybrid ensemble and AHP approach for resilient supplier selection. In: *Journal of Intelligent Manufacturing* 30 (1), S. 207–228.
- Hussy, W. (1984): *Denkpsychologie*. Stuttgart: Kohlhammer.
- Hussy, W. (1993): *Denken und Problemlösen*. Stuttgart: Kohlhammer.

-
- Inprasit, T.; Tanachutiwat, S. (2018): Reordering Point Determination Using Machine Learning Technique for Inventory Management. In: International Conference on Engineering, Applied Sciences, and Technology (ICEAST). IEEE, S. 1–4.
- Irranezhad, E.; Prato, C. G.; Hickman, M. (2020): An intelligent decision support system prototype for hinterland port logistics. In: Decision Support Systems 130.
- ISO (2022): Standards by ISO/IEC JTC 1/SC 42. International Organization for Standardization. Online verfügbar unter <https://www.iso.org/committee/6794475/x/catalogue/p/0/u/1/w/0/d/0>, zuletzt geprüft am 15.09.2022.
- ISO 16290:2013: Space systems - Definition of the Technology Readiness Levels (TRLs) and their criteria of assessment. Online verfügbar unter <https://www.iso.org/standard/56064.html>, zuletzt geprüft am 15.09.2022.
- ISO/IEC 23053:2022: Framework for Artificial Intelligence (AI) Systems Using Machine Learning (ML). Online verfügbar unter <https://www.iso.org/standard/74438.html>, zuletzt geprüft am 15.09.2022.
- ISO/IEC 2382:2015: Information technology - Vocabulary. Online verfügbar unter <https://www.iso.org/obp/ui/#iso:std:iso-iec:2382:ed-1:v1:en>, zuletzt geprüft am 15.09.2022.
- ISO/IEC 25010:2011: Systems and software engineering - Systems and software Quality Requirements and Evaluation (SQuaRE) - System and software quality models. Online verfügbar unter <https://www.iso.org/standard/35733.html>, zuletzt geprüft am 15.09.2022.
- ISO/SAE PAS 22736:2021: Taxonomy and definitions for terms related to driving automation systems for on-road motor vehicles. Online verfügbar unter <https://www.iso.org/standard/73766.html>, zuletzt geprüft am 15.09.2022.
- James, G.; Witten, D.; Hastie, T.; Tibshirani, R. (2013): An Introduction to Statistical Learning. New York: Springer.
- Jordan, M. I.; Mitchell, T. M. (2015): Machine learning: Trends, perspectives, and prospects. In: Science 349 (6245), S. 255–260.
- Joshi, A. V. (2020): Machine Learning and Artificial Intelligence. Cham: Springer International Publishing.
- Joshi, K. D.; Chauhan, V.; Surgenor, B. (2020): A flexible machine vision system for small part inspection based on a hybrid SVM/ANN approach. In: Journal of Intelligent Manufacturing 31 (1), S. 103–125.
- Kahle, E. (2001): Betriebliche Entscheidungen. Berlin, Boston: Oldenbourg Wissenschaftsverlag.
- Kaiser, L.; Gomez, A. N.; Shazeer, N.; Vaswani, A.; Parmar, N.; Jones, L.; Uszkoreit, J. (2017): One Model To Learn Them All. Online verfügbar unter <https://arxiv.org/pdf/1706.05137>, zuletzt geprüft am 15.09.2022.
- Karafillidis, A. (2019): Unterstützung und Assistenz durch die Maschine. In: Liggieri, K. und Müller, O. (Hrsg.): Mensch-Maschine-Interaktion. Stuttgart: J.B. Metzler, S. 157–164.
- Karaoglan, A. D.; Karademir, O. (2017): Flow time and product cost estimation by using an artificial neural network (ANN): A case study for transformer orders. In: The Engineering Economist 62 (3), S. 272–292.
- Kelle, U. (2019): Mixed Methods. In: Baur, N. und Blasius, J. (Hrsg.): Handbuch Methoden der empirischen Sozialforschung. Wiesbaden: Springer Fachmedien Wiesbaden, S. 159–172.
- Kelle, U.; Kluge, S. (2010): Vom Einzelfall zum Typus. Wiesbaden: VS Verlag für Sozialwissenschaften.
- Kersten, W.; Seiter, M.; See, B. v.; Hackius, N.; Maurer, T. (2017): Chancen der digitalen Transformation. Hamburg: DVV Media Group GmbH.
- Keusch, F. (2013): The Role of Topic Interest and Topic Salience in Online Panel Web Surveys. In: International Journal of Market Research 55 (1), S. 59–80.
- Khan, O.; Siddiqui, N.; Oleson, T.; Fussell, M. (2021): Embracing Microservices Design. Boston, MA: Packt Publishing.
- Kim, H.; Park, J.; Bennis, M.; Kim, S.-L. (2018): Blockchain On-Device Federated Learning. Online verfügbar unter <https://arxiv.org/pdf/1808.03949>, zuletzt geprüft am 15.09.2022.

-
- Klappert, S.; Schuh, G.; Aghassi, S. (2011): Einleitung und Abgrenzung. In: Schuh, G. und Klappert, S. (Hrsg.): *Technologiemanagement*. Berlin, Heidelberg: Springer, S. 5–10.
- Klemm, T. (2018): Roadmap: SAP Integrated Business Planning. SAP SE. Online verfügbar unter <https://blog.asug.com/hubfs/ASUG82242%20-%20Road%20Map%20SAP%20Integrated%20Business%20Planning.pdf>, zuletzt geprüft am 15.09.2022.
- Kluge, S. (1999): *Empirisch begründete Typenbildung*. Wiesbaden: VS Verlag für Sozialwissenschaften.
- Kniberg, H.; Ivarsson, A. (2012): Scaling Agile @ Spotify with Tribes, Squads, Chapters & Guilds. Crisp AB. Online verfügbar unter <https://blog.crisp.se/wp-content/uploads/2012/11/SpotifyScaling.pdf>, zuletzt geprüft am 15.09.2022.
- Knuth, D. E. (1974): Computer programming as an art. In: *Communications of the ACM* 17 (12), S. 667–673.
- Ko, T.; Lee, J. H.; Cho, H.; Cho, S.; Lee, W.; Lee, M. (2017): Machine learning-based anomaly detection via integration of manufacturing, inspection and after-sales service data. In: *Industrial Management & Data Systems* 117 (5), S. 927–945.
- Konečný, J.; McMahan, H. B.; Yu, F. X.; Richtárik, P.; Suresh, A. T.; Bacon, D. (2016): Federated Learning: Strategies for Improving Communication Efficiency. Online verfügbar unter <https://arxiv.org/pdf/1610.05492>, zuletzt geprüft am 15.09.2022.
- Konovalenko, I.; Ludwig, A. (2019): Event processing in supply chain management – The status quo and research outlook. In: *Computers in Industry* 105, S. 229–249.
- Koop, A.; Moock, H. (2018): *Lineare Optimierung – eine anwendungsorientierte Einführung in Operations Research*. Berlin, Heidelberg: Springer.
- Körner, S. (1980): Wissenschaft. In: Speck, J. (Hrsg.): *Handbuch wissenschaftstheoretischer Begriffe*, Band 3: R-Z. Göttingen: Vandenhoeck & Ruprecht, S. 726–737.
- Kornmeier, M. (2007): *Wissenschaftstheorie und wissenschaftliches Arbeiten*. Heidelberg: Physica-Verlag.
- Kotter, J. P. (2014): *Accelerate*. Boston: Harvard Business Review Press.
- Krauß, J.; Dorißen, J.; Mende, H.; Frye, M.; Schmitt, R. H. (2019): Maschinelles Lernen in der Produktion - Anwendungsgebiete und frei verfügbare Datensätze. In: *Industrie 4.0 Management* 2019 (4), S. 39–42.
- Kreutzer, R. T.; Sirenberg, M. (2019): *Künstliche Intelligenz verstehen*. Wiesbaden: Springer Fachmedien Wiesbaden.
- Kromrey, H. (2002): *Empirische Sozialforschung*. Wiesbaden: VS Verlag für Sozialwissenschaften.
- Kuckartz, U. (2010): Typenbildung. In: Mey, G. und Mruck, K. (Hrsg.): *Handbuch Qualitative Forschung in der Psychologie*. Wiesbaden: VS Verlag für Sozialwissenschaften, S. 553–568.
- Kucukoglu, I.; Atici-Ulusu, H.; Gunduz, T.; Tokcalar, O. (2018): Application of the artificial neural network method to detect defective assembling processes by using a wearable technology. In: *Journal of Manufacturing Systems* 49, S. 163–171.
- Kuhn, M.; Johnson, K. (2013): *Applied Predictive Modeling*. New York: Springer.
- Kurzwel, R. (2005): *The singularity is near*. New York: Viking.
- Lamnek, S. (2005): *Gruppendiskussion*. Weinheim, Basel: Beltz.
- Lau, H.; Ho, G.; Zhao, Y. (2013): A demand forecast model using a combination of surrogate data analysis and optimal neural network approach. In: *Decision Support Systems* 54 (3), S. 1404–1416.
- Laux, H.; Gillenkirch, R. M.; Schenk-Mathes, H. Y. (2018): *Entscheidungstheorie*. Berlin, Heidelberg: Springer.
- LeCun, Y.; Bengio, Y.; Hinton, G. (2015): Deep learning. In: *Nature* 521 (7553), S. 436–444.
- Leimeister, J. M. (2015): *Einführung in die Wirtschaftsinformatik*. Berlin, Heidelberg: Springer Gabler.

-
- Li, X.; Wang, J.; Sawhney, R. (2012): Reinforcement learning for joint pricing, lead-time and scheduling decisions in make-to-order systems. In: *European Journal of Operational Research* 221 (1), S. 99–109.
- Liashchynskiy, P. (2019): Grid Search, Random Search, Genetic Algorithm: A Big Comparison for NAS. Online verfügbar unter <https://arxiv.org/abs/1912.06059>, zuletzt geprüft am 15.09.2022.
- Lima-Junior, F. R.; Carpinetti, L. C. R. (2017): Quantitative models for supply chain performance evaluation: A literature review. In: *Computers & Industrial Engineering* 113, S. 333–346.
- Lima-Junior, F. R.; Carpinetti, L. C. R. (2019): Predicting supply chain performance based on SCOR metrics and multilayer perceptron neural networks. In: *International Journal of Production Economics* 212, S. 19–38.
- Lima-Junior, F. R.; Carpinetti, L. C. R. (2020): An adaptive network-based fuzzy inference system to supply chain performance evaluation based on SCOR metrics. In: *Computers & Industrial Engineering* 139.
- Lingitz, L.; Gallina, V.; Ansari, F.; Gyulai, D.; Pfeiffer, A.; Sihm, W.; Monostori, L. (2018): Lead time prediction using machine learning algorithms: A case study by a semiconductor manufacturer. In: *Procedia CIRP* 72, S. 1051–1056.
- Liu, C.; Shu, T.; Chen, S.; Wang, S.; Lai, K. K.; Gan, L. (2016): An improved grey neural network model for predicting transportation disruptions. In: *Expert Systems with Applications* 45, S. 331–340.
- Liu, Q.; Dong, M.; Chen, F. F. (2018): Single-machine-based joint optimization of predictive maintenance planning and production scheduling. In: *Robotics and Computer-Integrated Manufacturing* 51, S. 238–247.
- Lolli, F.; Balugani, E.; Ishizaka, A.; Gamberini, R.; Rimini, B.; Regattieri, A. (2019): Machine learning for multi-criteria inventory classification applied to intermittent demand. In: *Production Planning & Control* 30 (1), S. 76–89.
- Lünendonk, J. (2019): Künstliche Intelligenz. Eine Studie zum Status quo in deutschen Unternehmen und zu zukünftigen Anwendungsfällen. Lünendonk & Hossenfelder GmbH. Mindelheim.
- Luo, M.; Yan, H.-C.; Hu, B.; Zhou, J.-H.; Pang, C. K. (2015): A data-driven two-stage maintenance framework for degradation prediction in semiconductor manufacturing industries. In: *Computers & Industrial Engineering* 85, S. 414–422.
- Lv, Y.; Qin, W.; Yang, J.; Zhang, J. (2018): Adjustment mode decision based on support vector data description and evidence theory for assembly lines. In: *Industrial Management & Data Systems* 118 (8), S. 1711–1726.
- Ma, H.; Wang, Y.; Wang, K. (2018): Automatic detection of false positive RFID readings using machine learning algorithms. In: *Expert Systems with Applications* 91, S. 442–451.
- Maghrebi, M.; Sammut, C.; Waller, S. T. (2015): Feasibility study of automatically performing the concrete delivery dispatching through machine learning techniques. In: *Engineering, Construction and Architectural Management* 22 (5), S. 573–590.
- Mainzer, K. (2018): Künstliche Intelligenz – Wann übernehmen die Maschinen? Berlin, Heidelberg: Springer.
- Marsland, S. (2015): *Machine learning*. Boca Raton, FL: CRC Press.
- Martínez, A.; Schmuck, C.; Pereverzyev, S.; Pirker, C.; Haltmeier, M. (2020): A machine learning framework for customer purchase prediction in the non-contractual setting. In: *European Journal of Operational Research* 281 (3), S. 588–596.
- Mayring, P. (2002): *Einführung in die qualitative Sozialforschung*. Weinheim, Basel: Beltz.
- Mayring, P. (2010): *Qualitative Inhaltsanalyse*. In: Flick, U.; Kardorff, E. v. und Steinke, I. (Hrsg.): *Qualitative Forschung*. Reinbek bei Hamburg: rowohlt's enzyklopädie im Rowohlt Taschenbuch Verlag, S. 468–475.
- McKinsey (2016): *The age of analytics*. McKinsey Global Institute.
- Meyer, J.-A. (2003): Die Fallstudie in der betriebswirtschaftlichen Forschung und Lehre. In: *WiSt - Wirtschaftswissenschaftliches Studium* 32 (8), S. 475–480.

-
- Michalski, R. S.; Carbonell, J. G.; Mitchell, T. M. (1983): *Machine Learning*. Berlin, Heidelberg: Springer.
- Microsoft Corporation (2022): Team Data Science Process. Online verfügbar unter <https://learn.microsoft.com/en-us/azure/architecture/data-science-process/overview>, zuletzt geprüft am 15.09.2022.
- Min, H. (2010): Artificial intelligence in supply chain management. Theory and applications. In: *International Journal of Logistics Research and Applications* 13 (1), S. 13–39.
- Mitchell, M.; Wu, S.; Zaldivar, A.; Barnes, P.; Vasserman, L.; Hutchinson, B. et al. (2019): Model Cards for Model Reporting. In: *Proceedings of the Conference on Fairness, Accountability, and Transparency*. New York: ACM, S. 220–229.
- Mitchell, T. M. (1997): *Machine Learning*. New York: McGraw-Hill.
- Mockenhaupt, A. (2021): *Digitalisierung und Künstliche Intelligenz in der Produktion*. Wiesbaden: Springer Fachmedien Wiesbaden.
- Mori, J.; Kajikawa, Y.; Kashima, H.; Sakata, I. (2012): Machine learning approach for finding business partners and building reciprocal relationships. In: *Expert Systems with Applications* 39 (12), S. 10402–10407.
- Mortazavi, A.; Arshadi Khamseh, A.; Azimi, P. (2015): Designing of an intelligent self-adaptive model for supply chain ordering management system. In: *Engineering Applications of Artificial Intelligence* 37, S. 207–220.
- Mortenson, M. J.; Doherty, N. F.; Robinson, S. (2015): Operational research from Taylorism to Terabytes: A research agenda for the analytics age. In: *European Journal of Operational Research* 241 (3), S. 583–595.
- Murphy, K. P. (2012): *Machine learning*. Cambridge, Massachusetts / London: The MIT Press.
- Nasiri, M. M.; Yazdanparast, R.; Jolai, F. (2017): A simulation optimisation approach for real-time scheduling in an open shop environment using a composite dispatching rule. In: *International Journal of Computer Integrated Manufacturing* 30 (12), S. 1239–1252.
- Nerdinger, F. W.; Blickle, G.; Schaper, N. (2011): *Arbeits- und Organisationspsychologie*. Berlin, Heidelberg: Springer.
- Newell, A.; Simon, H. A. (1976): Computer science as empirical inquiry. In: *Communications of the ACM* 19 (3), S. 113–126.
- Ngai, E.; Peng, S.; Alexander, P.; Moon, K. K. (2014): Decision support and intelligent systems in the textile and apparel supply chain: An academic review of research articles. In: *Expert Systems with Applications* 41 (1), S. 81–91.
- Ni, D.; Xiao, Z.; Lim, M. K. (2019): A systematic review of the research trends of machine learning in supply chain management. In: *International Journal of Machine Learning and Cybernetics* 7 (1), S. 1463–1482.
- Nilsson, N. J. (2010): *The quest for artificial intelligence*. Cambridge: Cambridge University Press.
- Ning, F.; Shi, Y.; Cai, M.; Xu, W.; Zhang, X. (2020): Manufacturing cost estimation based on a deep-learning method. In: *Journal of Manufacturing Systems* 54, S. 186–195.
- Oliveira, T.; Martins, M. R. (2011): Literature Review of Information Technology Adoption Models at Firm Level. In: *The Electronic Journal Information Systems Evaluation* 14 (1), S. 110–121.
- Owczarek, T.; Janke, P. (2018): Predictive Business Process Monitoring with Tree-based Classification Algorithms. In: *Logistics and Transport* (40), S. 73–82.
- Papananias, M.; McLeay, T. E.; Mahfouf, M.; Kadirkamanathan, V. (2019): A Bayesian framework to estimate part quality and associated uncertainties in multistage manufacturing. In: *Computers in Industry* 105, S. 35–47.
- Partsch, H. (2010): *Requirements-Engineering systematisch*. Berlin, Heidelberg: Springer.
- Patel, K.; Fogarty, J.; Landay, J.; Harrison, B. (2008): Examining Difficulties Software Developers Encounter in the Adoption of Statistical Machine Learning. In: *Proceedings of the National Conference on Artificial Intelligence* 3, S. 1563–1566.

-
- Peidro, D.; Mula, J.; Poler, R.; Lario, F.-C. (2009): Quantitative models for supply chain planning under uncertainty: a review. In: *The International Journal of Advanced Manufacturing Technology* 43 (3-4), S. 400–420.
- Penrose, E. T. (1997): *The theory of the growth of the firm*. Oxford: Oxford Univ. Press.
- Pflaum, A.; Schwemmer, M.; Gundelfinger, C.; Naumann, V. (2017): *Transportlogistik 4.0*. Erlangen: Fraunhofer-Institut für Integrierte Schaltungen IIS.
- Pfohl, H.-C. (1977): *Problemorientierte Entscheidungsfindung in Organisationen*. Berlin: De Gruyter.
- Pfohl, H.-C. (2010): *Logistiksysteme*. Berlin, Heidelberg: Springer.
- Pfohl, H.-C. (2016): *Logistikmanagement*. Berlin, Heidelberg: Springer.
- Porter, M. E. (1998): *Competitive strategy*. New York: Free Press.
- Prahalad, C. K.; Hamel, G. (2006): The Core Competence of the Corporation. In: Hahn, D. und Taylor, B. (Hrsg.): *Strategische Unternehmungsplanung - strategische Unternehmungsführung*. Berlin, Heidelberg: Springer, S. 275–292.
- Priem, R. L.; Butler, J. E. (2001): Is the Resource-Based "View" a Useful Perspective for Strategic Management Research? In: *Academy of Management Review* 26 (1), S. 22–40.
- Puchalsky, W.; Ribeiro, G. T.; Da Veiga, C. P.; Freire, R. Z.; Santos Coelho, L. d. (2018): Agribusiness time series forecasting using Wavelet neural networks and metaheuristic optimization: An analysis of the soybean sack price and perishable products demand. In: *International Journal of Production Economics* 203, S. 174–189.
- Puppe, F. (1990): *Problemlösungsmethoden in Expertensystemen*. Berlin, Heidelberg: Springer.
- PwC (2017): *What's the real value of AI for your business and how can you capitalise*. PricewaterhouseCoopers International Limited.
- PwC (2018): *Auswirkungen der Nutzung von künstlicher Intelligenz in Deutschland*. PricewaterhouseCoopers GmbH Wirtschaftsprüfungsgesellschaft.
- Raffée, H. (1993): *Grundprobleme der Betriebswirtschaftslehre*. Göttingen: Vandenhoeck & Ruprecht.
- Reder, B. (2020): *Studie Machine Learning 2020*. Computerwoche, CIO, TecChannel, ChannelPartner. IDG Research Service.
- Reichertz, J. (2016): *Qualitative und interpretative Sozialforschung: Eine Einladung*. Wiesbaden: Springer Fachmedien Wiesbaden.
- Reipert, J. (2019): *Open Innovation in der Logistik*. Berlin: Universitätsverlag der TU Berlin.
- Ren, S.; Choi, T.-M.; Lee, K.-M.; Lin, L. (2020): Intelligent service capacity allocation for cross-border E-commerce related third-party-forwarding logistics operations: A deep learning approach. In: *Transportation Research Part E: Logistics and Transportation Review* 134.
- Renz, K.-C. (2004): *Technologiestrategien in wachsenden und schnell wachsenden Unternehmen*. Heimsheim: Jost-Jetter.
- Rhensius, T. (2010): *Typisierung von RFID-Anwendungen*. Aachen: Apprimus-Verlag.
- Rich, E. (1983): *Artificial intelligence*. New York: McGraw-Hill.
- Rich, E. (1985): Artificial Intelligence and the Humanities. In: *Computers and the Humanities* 19 (2), S. 117–122.
- Richter, S. (2019): *Statistisches und maschinelles Lernen*. Berlin, Heidelberg: Springer.
- Riesenhuber, M. (2006): *Die Fehlentscheidung*. Wiesbaden: Deutscher Universitätsverlag.
- Rodrigues, R.; Siemaszko, K.; Warso, Z. (2019): SIENNA D4.2: Analysis of the legal and human rights requirements for AI and robotics in and outside the EU.
- Rogers, E. M. (1983): *Diffusion of innovations*. New York: Free Press.
- Rohde, J.; Meyr, H.; Wagner, M. (2000): Die Supply Chain Planning Matrix. In: *PPS-Management* 5 (1), S. 10–15.

-
- Rokach, L.; Hutter, D. (2012): Automatic discovery of the root causes for quality drift in high dimensionality manufacturing processes. In: *Journal of Intelligent Manufacturing* 23 (5), S. 1915–1930.
- Roy, D. T. (2017): *Industrie 4.0 - Gestaltung cyber-physischer Logistiksysteme zur Unterstützung des Logistikmanagements in der Smart Factory*. Berlin: Universitätsverlag der TU Berlin.
- Ruder, S. (2017): An Overview of Multi-Task Learning in Deep Neural Networks. Online verfügbar unter <https://arxiv.org/pdf/1706.05098>, zuletzt geprüft am 15.09.2022.
- Rueden, L. v.; Mayer, S.; Beckh, K.; Georgiev, B.; Giesselbach, S.; Heese, R. et al. (2019): Informed Machine Learning - A Taxonomy and Survey of Integrating Knowledge into Learning Systems. Online verfügbar unter <https://arxiv.org/pdf/1903.12394>, zuletzt geprüft am 15.09.2022.
- Russell, S. J.; Norvig, P. (2012): *Künstliche Intelligenz*. München, Harlow, Amsterdam: Pearson Higher Education.
- Russell, S. J.; Norvig, P. (2016): *Artificial intelligence*. Boston, Columbus, Indianapolis: Pearson.
- Sammut, C.; Webb, G. I. (2017): *Encyclopedia of Machine Learning and Data Mining*. Boston: Springer.
- Samuel, A. L. (1959): Some Studies in Machine Learning Using the Game of Checkers. In: *IBM Journal of Research and Development* 3 (3), S. 210–229.
- Sanchez, R.; Heene, A. (1997): Reinventing strategic management: New theory and practice for competence-based competition. In: *European Management Journal* 15 (3), S. 303–317.
- Santis, R. B. de; Aguiar, E. P. de; Goliatt, L. (2017): Predicting material backorders in inventory management using machine learning. In: *IEEE Latin American Conference on Computational Intelligence (LA-CCI)*. IEEE, S. 1–6.
- SAS (2022): Introduction to SEMMA. SAS Institute Inc. Online verfügbar unter <https://documentation.sas.com/doc/en/emref/14.3/n061bzurmej43n1jnjb8bbjm1a2.htm>, zuletzt geprüft am 15.09.2022.
- Schmidhuber, J. (2015): Deep learning in neural networks: an overview. In: *Neural networks: the official journal of the International Neural Network Society* 61, S. 85–117.
- Schreyögg, G.; Koch, J. (2020): *Management*. Wiesbaden: Springer Fachmedien Wiesbaden.
- Schuh, G.; Stich, V. (2013): *Logistikmanagement*. Berlin, Heidelberg: Springer.
- Schuld, M.; Petruccione, F. (2018): *Supervised learning with quantum computers*. Cham: Springer.
- Schulte-Gehrmann, A.-L.; Klappert, S.; Schuh, G.; Hoppe, M. (2011): Technologiestrategie. In: Schuh, G. und Klappert, S. (Hrsg.): *Technologiemanagement*. Berlin, Heidelberg: Springer, S. 55–88.
- Schwarze, J. (2000): *Einführung in die Wirtschaftsinformatik*. Herne, Berlin: Verlag Neue Wirtschafts-Briefe.
- Sculley, D.; Holt, G.; Golovin, D.; Davydov, E.; Phillips, T.; Ebner, D. et al. (2015): Hidden Technical Debt in Machine Learning Systems. In: Cortes, C.; Lee, D. D.; Sugiyama, M. und Garnett, R. (Hrsg.): *Proceedings of the 28th International Conference on Neural Information Processing Systems*. Cambridge, Massachusetts: MIT Press, S. 2503–2511.
- Searle, J. R. (1980): Minds, brains, and programs. In: *Behavioral and Brain Sciences* 3 (3), S. 417–424.
- See, B. v. (2019): *Ein Handlungsrahmen für die digitale Transformation in Wertschöpfungsnetzwerken*. Hamburg.
- See, B. v.; Kersten, W. (2017): Digitale Transformation des Arbeitsumfelds. In: Gronau, N. (Hrsg.): *Industrial Internet of Things in der Arbeits- und Betriebsorganisation*. Berlin: GITO Verlag, S. 91–117.
- See, B. v.; Kersten, W. (2018): Arbeiten im Zeitalter des Internets der Dinge. In: *Industrie 4.0 Management* 2018 (3), S. 8–12.
- Seifert, I.; Bürger, M.; Wangler, L.; Christmann-Budian, S.; Rohde, M.; Gabriel, P.; Zinke, G. (2018): *Potenziale der Künstlichen Intelligenz im produzierenden Gewerbe in Deutschland*. iit-Institut für Innovation und Technik in der VDI / VDE Innovation + Technik GmbH. Berlin.

-
- Senapathi, M.; Buchan, J.; Osman, H. (2019): DevOps Capabilities, Practices, and Challenges. In: Proceedings of the 22nd International Conference on Evaluation and Assessment in Software Engineering, S. 57–67.
- Sharma, R.; Kamble, S. S.; Gunasekaran, A.; Kumar, V.; Kumar, A. (2020): A systematic literature review on machine learning applications for sustainable agriculture supply chain performance. In: Computers & Operations Research 119.
- Shin, D. H.; Dunston, P. S. (2008): Identification of application areas for Augmented Reality in industrial construction based on technology suitability. In: Automation in Construction 17 (7), S. 882–894.
- Silva, N.; Ferreira, L. M. D.; Silva, C.; Magalhães, V.; Neto, P. (2017): Improving Supply Chain Visibility With Artificial Neural Networks. In: Procedia Manufacturing 11, S. 2083–2090.
- Silver, D.; Schrittwieser, J.; Simonyan, K.; Antonoglou, I.; Huang, A.; Guez, A. et al. (2017): Mastering the game of Go without human knowledge.
- Simon, H. A. (1983): Why Should Machines Learn? In: Michalski, R. S.; Carbonell, J. G. und Mitchell, T. M. (Hrsg.): Machine Learning. Berlin, Heidelberg: Springer, S. 25–37.
- Singh, S.; Soni, U. (2019): Predicting Order Lead Time for Just in Time production system using various Machine Learning Algorithms: A Case Study. In: 9th International Conference on Cloud Computing, Data Science & Engineering (Confluence). IEEE, S. 422–425.
- Singh, V.; Sarwar, F.; Chan, F.; Tiwari, M. K. (2012): Monitoring the performance of conveyor system using radio frequency identification in manufacturing environment: a recurrent neural network and genetic algorithm-based approach. In: International Journal of Computer Integrated Manufacturing 25 (7), S. 551–564.
- Sommerlatte, T.; Deschamps, J.-P. (1985): Der strategische Einsatz von Technologien. In: Management im Zeitalter der strategischen Führung. Wiesbaden: Gabler, S. 37–76.
- Spath, D. (2018): Lernende Systeme in Wirtschaft und Gesellschaft. In: Bär, C.; Grädler, T. und Mayr, R. (Hrsg.): Digitalisierung im Spannungsfeld von Politik, Wirtschaft, Wissenschaft und Recht. Berlin, Heidelberg: Springer, S. 505–520.
- Spies, R.; Grobbelaar, S.; Botha, A. (2020): A Scoping Review of the Application of the Task-Technology Fit Theory. In: Hattingsh, M.; Matthee, M.; Smuts, H. et al. (Hrsg.): Responsible Design, Implementation and Use of Information and Communication Technology. Cham: Springer International Publishing, S. 397–408.
- Stahlknecht, P.; Hasenkamp, U. (2002): Einführung in die Wirtschaftsinformatik. Berlin, Heidelberg: Springer.
- Straube, F. (2004): e-Logistik. Berlin, Heidelberg: Springer.
- Straube, F. (2019): Pathway of digital transformation in logistics. Unter Mitarbeit von Junge, A. L.; Verhoeven, P.; Reipert, J. und Mansfeld, M. Berlin: Universitätsverlag der TU Berlin.
- Straube, F. (2020): Grundlagen der Logistik - Einführung, Megatrends und Logistikstrategien. Vorlesungsunterlagen. Berlin: Technische Universität Berlin.
- Straube, F.; Poschmann, P.; Weinke, M.; Friedrich, H.; Ludwig, A.; Balster, A. (2020a): Smart Event Forecast for Seaports (SMECS) - Schlussbericht. Technische Universität Berlin. Online verfügbar unter <https://doi.org/10.2314/KXP:1750824116>, zuletzt geprüft am 15.09.2022.
- Straube, F.; Weinke, M.; Poschmann P. (2020b): Hohes Potenzial für lernende Systeme in logistischen Entscheidungsprozessen. In: Logistik für Unternehmen (06-07), S. 59–63.
- Stroh, O.; Ulich, E. (1997): Unternehmen arbeitspsychologisch bewerten. Zürich: vdf Hochschulverlag AG an der ETH Zürich.
- Strübing, J. (2013): Qualitative Sozialforschung: Oldenbourg Wissenschaftsverlag Verlag.
- Sun, R.; Zhao, G. (2012): Analyses about efficiency of reinforcement learning to supply chain ordering management. In: IEEE 10th International Conference on Industrial Informatics. IEEE, S. 124–127.
- Sustrova, T. (2016): A Suitable Artificial Intelligence Model for Inventory Level Optimization. In: Trends Economics and Management 10 (25), S. 48–55.

-
- Tanaka, F. H.; Aranha, C. (2019): Data Augmentation Using GANs. Online verfügbar unter <https://arxiv.org/pdf/1904.09135>, zuletzt geprüft am 15.09.2022.
- Technische Universität Berlin (2020): SMECS Demonstrator. Online verfügbar unter <https://smecs.logistik.tu-berlin.de/>, zuletzt geprüft am 15.09.2022.
- Teece, D. J. (2007): Explicating dynamic capabilities: the nature and microfoundations of (sustainable) enterprise performance. In: *Strategic Management Journal* 28 (13), S. 1319–1350.
- Teece, D. J.; Pisano, G.; Shuen, A. (1997): Dynamic capabilities and strategic management. In: *Strategic Management Journal* 18 (7), S. 509–533.
- Tenzer, F. (2020): Prognose zum weltweit generierten Datenvolumen 2025. Statista. Online verfügbar unter <https://de.statista.com/statistik/daten/studie/267974/umfrage/prognose-zum-weltweit-generierten-datenvolumen>, zuletzt geprüft am 15.09.2022.
- Thommen, J.-P.; Achleitner, A.-K.; Gilbert, D. U.; Hachmeister, D.; Kaiser, G. (2017): Wissensmanagement. In: Thommen, J.-P.; Achleitner, A.-K.; Gilbert, D. U. et al. (Hrsg.): *Allgemeine Betriebswirtschaftslehre: Umfassende Einführung aus managementorientierter Sicht*. Wiesbaden: Springer Fachmedien Wiesbaden, S. 551–560.
- Thyssenkrupp Materials Services (2019): Nächster Meilenstein in der digitalen Transformation: thyssenkrupp präsentiert künstliche Intelligenz „alfred“. Online verfügbar unter <https://www.thyssenkrupp.com/de/newsroom/pressemeldungen/naechster-meilenstein-in-der-digitalen-transformation--thyssenkrupp-praesentiert-kuenstliche-intelligenz--alfred--12418.html>, zuletzt geprüft am 15.09.2022.
- Tian, X.; Liu, L.; Lai, K. K.; Wang, S. (2013): Analysis and forecasting of port logistics using TEI@I methodology. In: *Transportation Planning and Technology* 36 (8), S. 685–702.
- Tornatzky, L. G.; Fleischer, M. (1990): *The processes of technological innovation*. Lexington, Massachusetts: Lexington Books.
- Tran, K. P.; Du Nguyen, H.; Thomassey, S. (2019): Anomaly detection using Long Short Term Memory Networks and its applications in Supply Chain Management. In: *IFAC-PapersOnLine* 52 (13), S. 2408–2412.
- Tranfield, D.; Denyer, D.; Smart, P. (2003): Towards a Methodology for Developing Evidence-Informed Management Knowledge by Means of Systematic Review. In: *British Journal of Management* 14 (3), S. 207–222.
- Turing, A. M. (1950): Computing Machinery and Intelligence. In: *Mind, New Series* 59 (236), S. 433–460.
- Ulrich, E. (2013): Arbeitssysteme als Soziotechnische Systeme – eine Erinnerung. In: *Journal Psychologie des Alltagshandelns* 6 (1), S. 4–12.
- Ulrich, H. (1981): Die Betriebswirtschaftslehre als anwendungsorientierte Sozialwissenschaft. In: Geist, M. und Köhler, R. (Hrsg.): *Die Führung des Betriebes*. Stuttgart: Poeschel, S. 1–25.
- Ulrich, H. (1984): *Management*. Bern, Stuttgart: Haupt.
- Ulrich, H. (2001): *Gesammelte Schriften - Band 4 - Management: Aufsätze 1970 – 1981*. Bern: Haupt.
- Ulrich, P.; Hill, W. (1979): Wissenschaftstheoretische Aspekte ausgewählter betriebswirtschaftlicher Konzeptionen. In: Raffée, H. und Abel, B. (Hrsg.): *Wissenschaftstheoretische Grundfragen der Wirtschaftswissenschaften*. München: Vahlen, S. 161–190.
- VDMA (2019): *Leitfaden Selbstlernende Produktionsprozesse*. VDMA; FKM Forschungskuratorium Maschinenbau e.V.; Institut für Unternehmenskybernetik e.V.
- Venkatesh, V.; Davis, F. D. (2000): A Theoretical Extension of the Technology Acceptance Model: Four Longitudinal Field Studies. In: *Management Science* 46 (2), S. 186–204.
- Vogel-Heuser, B.; Bauernhansl, T.; Hompel, M. ten (2017): *Handbuch Industrie 4.0 Band 4*. Berlin, Heidelberg: Springer.
- Wagner-Schelewsky, P.; Hering, L. (2019): Online-Befragung. In: Baur, N. und Blasius, J. (Hrsg.): *Handbuch Methoden der empirischen Sozialforschung*. Wiesbaden: Springer Fachmedien Wiesbaden, S. 787–800.

-
- Wahlster, W. (2001): Werden Maschinen den Menschen ersetzen? Über die Grenzen der Künstlichen Intelligenz. Deutsches Forschungszentrum für Künstliche Intelligenz GmbH, Saarbrücken. Online verfügbar unter http://www.dfki.de/wwdata/Werden_Maschinen_den_Menschen_ersetzen/index.html, zuletzt geprüft am 15.09.2022.
- Wahlster, W. (2017): Künstliche Intelligenz als Grundlage autonomer Systeme. In: Informatik-Spektrum 40 (5), S. 409–418.
- Wahlster, W.; Winterhalter, C. (2020): Deutsche Normungsroadmap Künstliche Intelligenz. DIN e.V.; DKE Deutsche Kommission Elektrotechnik.
- Wang, H.; Fu, Y.; Huang, M.; Huang, G. Q.; Wang, J. (2017a): A NSGA-II based memetic algorithm for multiobjective parallel flowshop scheduling problem. In: Computers & Industrial Engineering 113, S. 185–194.
- Wang, H.; Jiang, Z.; Zhang, X.; Wang, Y.; Wang, Y. (2017b): A fault feature characterization based method for remanufacturing process planning optimization. In: Journal of Cleaner Production 161, S. 708–719.
- Wang, J.; Ma, Y.; Zhang, L.; Gao, R. X.; Wu, D. (2018a): Deep learning for smart manufacturing: Methods and applications. In: Journal of Manufacturing Systems 48, S. 144–156.
- Wang, J.; Zhang, J.; Wang, X. (2018b): Bilateral LSTM: A Two-Dimensional Long Short-Term Memory Model With Multiply Memory Units for Short-Term Cycle Time Forecasting in Re-entrant Manufacturing Systems. In: IEEE Transactions on Industrial Informatics 14 (2), S. 748–758.
- Wang, L.; Kowk, S. K.; Ip, W. H. (2012): A radio frequency identification-based quality evaluation system design for the wine industry. In: International Journal of Computer Integrated Manufacturing 25 (1), S. 11–19.
- Wang, S.; Liang, Y. C.; Li, W. D.; Cai, X. T. (2018c): Big Data enabled Intelligent Immune System for energy efficient manufacturing management. In: Journal of Cleaner Production 195, S. 507–520.
- Ward, J. H. (1963): Hierarchical Grouping to Optimize an Objective Function. In: Journal of the American Statistical Association 58 (301), S. 236–244.
- Weber, F. (2020): Künstliche Intelligenz für Business Analytics. Wiesbaden: Springer Fachmedien Wiesbaden.
- Weinberger, T.; Keller, H. B.; Jakob, W.; Grosse Osterhues, B. (1994): Modelle Maschinellen Lernens. Symbolische und konnektionistische Ansätze. Kernforschungszentrum Karlsruhe GmbH, Karlsruhe.
- Welter, M. (2006): Die Forschungsmethode der Typisierung. In: WiSt - Wirtschaftswissenschaftliches Studium 35 (2), S. 113–116.
- Wen, L.; Gao, L.; Li, X. (2019): A New Deep Transfer Learning Based on Sparse Auto-Encoder for Fault Diagnosis. In: IEEE Transactions on Systems, Man, and Cybernetics: Systems 49 (1), S. 136–144.
- Wentura, D.; Pospeschill, M. (2015): Clusteranalyse. In: Wentura, D. und Pospeschill, M. (Hrsg.): Multivariate Datenanalyse. Wiesbaden: Springer Fachmedien Wiesbaden, S. 165–179.
- Wenzel, H.; Smit, D.; Sardesai, S. (2019): A Literature Review on Machine Learning in Supply Chain Management. In: Kersten, W.; Blecker, T. und Ringle, C. M. (Hrsg.): Artificial Intelligence and Digital Transformation in Supply Chain Management. epubli GmbH: Berlin, S. 417–444.
- Wernerfelt, B. (1984): A Resource-Based View of the Firm. In: Strategic Management Journal 5 (2), S. 171–180.
- Wirth, R.; Hipp, J. (2000): CRISP-DM: Towards a standard process model for data mining. In: Proceedings of the 4th International Conference on the Practical Applications of Knowledge Discovery and Data Mining.
- Wittpahl, V. (2019): Künstliche Intelligenz. Berlin, Heidelberg: Springer.
- Wodecki, A. (2019): Artificial Intelligence in Value Creation. Cham: Springer International Publishing.
- Wolan, M. (2020): Next Generation Digital Transformation. Wiesbaden: Springer Fachmedien Wiesbaden.

-
- Wolpert, D. H.; Macready, W. G. (1997): No free lunch theorems for optimization. In: IEEE Transactions on Evolutionary Computation 1 (1), S. 67–82.
- Worapradya, K.; Thanakijkasem, P. (2015): Proactive Scheduling for Steelmaking-Continuous Casting Plant with Uncertain Machine Breakdown Using Distribution-Based Robustness and Decomposed Artificial Neural Network. In: Asia-Pacific Journal of Operational Research 32 (02), S. 1–22.
- Xing, E. P.; Ho, Q.; Xie, P.; Dai, W. (2015): Strategies and Principles of Distributed Machine Learning on Big Data. Online verfügbar unter <https://arxiv.org/pdf/1512.09295>, zuletzt geprüft am 15.09.2022.
- Yang, C.-L.; Sutrisno, H. (2018): Short-Term Sales Forecast of Perishable Goods for Franchise Business. In: 10th International Conference on Knowledge and Smart Technology (KST). IEEE, S. 101–105.
- Yang, Q.; Liu, Y.; Chen, T.; Tong, Y. (2019): Federated Machine Learning: Concept and Applications. Online verfügbar unter <https://arxiv.org/pdf/1902.04885>, zuletzt geprüft am 15.09.2022.
- Ye, S.; Xiao, Z.; Zhu, G. (2015): Identification of supply chain disruptions with economic performance of firms using multi-category support vector machines. In: International Journal of Production Research 53 (10), S. 3086–3103.
- Yin, R. K. (2009): Case study research. Los Angeles: Sage.
- Yin, X.; Niu, Z.; He, Z.; Li, Z.; Lee, D. (2020): An integrated computational intelligence technique based operating parameters optimization scheme for quality improvement oriented process-manufacturing system. In: Computers & Industrial Engineering 140.
- Zage, D.; Glass, K.; Colbaugh, R. (2013): Improving supply chain security using big data. In: IEEE International Conference on Intelligence and Security Informatics. IEEE, S. 254–259.
- Zhang, C.; Jiang, P. (2020): RFID-Driven Energy-Efficient Control Approach of CNC Machine Tools Using Deep Belief Networks. In: IEEE Transactions on Automation Science and Engineering 17 (1), S. 129–141.
- Zhang, D.; Mishra, S.; Brynjolfsson, E.; Etchemendy, J.; Ganguli, D.; Grosz, B. et al. (2021): The AI Index 2021 Annual Report. AI Index Steering Committee, Human-Centered AI Institute, Stanford University, Stanford. Online verfügbar unter <https://arxiv.org/pdf/2103.06312>, zuletzt geprüft am 15.09.2022.
- Zhang, J.; Qin, W.; Wu, L. H.; Zhai, W. B. (2014): Fuzzy neural network-based rescheduling decision mechanism for semiconductor manufacturing. In: Computers in Industry 65 (8), S. 1115–1125.
- Zheng, S.; Gupta, C.; Serita, S. (2019): Manufacturing Dispatching Using Reinforcement and Transfer Learning. In: Machine Learning and Knowledge Discovery in Databases: European Conference, ECML PKDD Proceedings, Part III. Berlin, Heidelberg: Springer, S. 655–671.
- Zhu, X.; Goldberg, A. B. (2009): Introduction to semi-supervised learning. San Rafael, Calif.: Morgan & Claypool.
- Zhu, Y. (2019): Closing the Perception-action Loop: Towards General-purpose Robot Autonomy. Stanford: Stanford University.

Schriftenreihe Logistik der Technischen Universität Berlin

Hrsg.: Frank Straube, Raimund Klinkner, Helmut Baumgarten

ISSN 1865-3170 (print)

ISSN 2197-0564 (online)

- 01: Mayer, Axel: Modularisierung der Logistik.** Ein Gestaltungsmodell zum Management von Komplexität in der industriellen Logistik. - 2007. - XVIII, 264 S.
ISBN 978-3-7983-2054-3 vergriffen
- 02: Thom, Alexander: Entwicklung eines Gestaltungsmodells zum Management von Risiken in Produktionsnetzwerken.** Ein Beitrag zum Risikomanagement in der Logistik. - 2008. - XX, 239 S.
ISBN 978-3-7983-2975-8 EUR 5,00
- 03: Bogatu, Christian: Smartcontainer als Antwort auf logistische und sicherheitsrelevante Herausforderungen in der Lieferkette.** Auswirkungen und Handlungsempfehlungen für die Wertschöpfungskette der Logistik. - 2008. - XXIV, 286 S.
ISBN 978-3-7983-2074-1 EUR 5,00
- 04: Beckmann, Thomas: Emerging Market Sourcing.** Eine empirische Untersuchung zu Erfolgsfaktoren in der Beschaffung aus Wachstumsmärkten. - 2008. -XI, 221 S.
ISBN 978-3-7983-2096-3 EUR 5,00
- 05: Dietman, Nils von: Airport Performance Measurement.** Kennzahlensystem zur Analyse und Bewertung von Flughafenprozessen. - 2008. - XXI, 204 S.
ISBN 978-3-7983-2103-8 EUR 5,00
- 06: Hildebrand, Wolf-Christian: Management von Transportnetzwerken im containerisierten Seehafenhinterlandverkehr.** - 2008. - XVI, 234 S.
ISBN 978-3-7983-2102-1 EUR 5,00
- 07: Wilmking, Niklas: Logistikmanagement in China.** Eine empirische Untersuchung zur Strategieentwicklung von Logistikdienstleistern. - 2009. - VIII, 247 S.
ISBN 978-3-7983-2130-4 EUR 5,00
- 08: Vogeler, Stefan: Entwicklung eines Vorgehensmodells zur Implementierung der RFID-Technologie in logistischen Systemen am Beispiel der Bekleidungsirtschaft.** - 2009. - XI, 227 S.
ISBN 978-3-7983-2156-4 EUR 5,00
- 09: Doch, Stefan Alexander: Logistische Leistungsdifferenzierung im Supply Chain Management.** Theoretische und empirische Entwicklung eines Gestaltungsansatzes für die Differenzierung der logistischen Leistungserstellung produzierender Unternehmen zur Erfüllung individueller Kundenwünsche. - 2009. - X, 271 S.
ISBN 978-3-7983-2157-1 vergriffen
- 10: Bensel, Philipp: Geschäftsmodelle von Logistikdienstleistern im Umfeld des Ubiquitous Computing.** - 2009. - XIV, 247 S.
ISBN 978-3-7983-2166-3 EUR 5,00
- 11: Bohn, Michael: Logistik im Kontext des ausländischen Markteintritts.** Entwicklung von Gestaltungsempfehlungen für den ausländischen Markteintritt unter besonderer Berücksichtigung der Erfolgskomponente Logistik. - 2009. - XVIII, 334 S.
ISBN 978-3-7983-2179-3 EUR 5,00
- 12: Sommer-Dittrich, Thomas: Wandlungsfähige Logistiksysteme in einer nachhaltigen Kreislaufwirtschaft.** - 2010. - 215 S.
ISBN 978-3-7983-2200-4 EUR 5,00
- 13: Kerner, Jürgen Andreas: Beschaffung im Eigenmarkengeschäft des Bekleidungshandels.** Ein theoretischer und fallstudienbasierter Beitrag zur Lösung ausgewählter Probleme der Prozessplanung. - 2010. - XX, 207 S.
ISBN 978-3-7983-2212-7 EUR 5,00
- 14: Fürstenberg, Frank: Der Beitrag serviceorientierter IT-Architekturen zu integrierten Kontraktlogistikdienstleistungen.** - 2010. - XVIII, 244 S.
ISBN 978-3-7983-2227-1 EUR 5,00

- 15: Fendt, Thomas: Introducing Electronic Supply Chain Collaboration in China – Evidence from Manufacturing Industries.** - 2010. - XII, 219, 53 S.
ISBN 978-3-7983-2243-1 EUR 5,00
- 16: Franke, Peter D.: Internationalisierung der Kontraktlogistik.** Entwicklung eines Instrumentariums zur Länderselektion. - 2011. - XV, 217 S.
ISBN 978-3-7983-2296-7 EUR 5,00
- 17: Tentrop, Friedrich: Entwicklung eines integrierten Gestaltungsansatzes der Produktionslogistik.** - 2011. - XV, 227 S.
ISBN 978-3-7983-2317-9 EUR 5,00
- 18: Nagel, Arnfried: Logistik im Kontext der Nachhaltigkeit.** Ökologische Nachhaltigkeit als Zielgröße bei der Gestaltung logistischer Netzwerke. - 2011. - XV, 228 S.
ISBN 978-3-7983-2383-4 EUR 5,00
- 19: Grig, Roman: Governance-Strukturen in der maritimen Transportkette.** Agentenbasierte Modellierung des Akteursverhaltens im Extended Gate. - 2012. - XVI, 373 S.
ISBN 978-3-7983-2384-1 EUR 5,00
- 20: Keßler, Martin: Gestaltung von Logistiknetzwerken für die humanitäre Versorgung in Entwicklungsländern Afrikas.** - 2012. - XIV, 355 S.
ISBN 978-3-7983-2426-8 (print) EUR 5,00
ISBN 978-3-7983-2427-5 (online)
- 21: Schwarz, Jennifer Rebecca: Humanitäre Logistik für die Versorgungsproblematik in Subsahara-Afrika.** Aufbau von Logistikkapazität durch Wissenstransfer. - 2012. - XVIII, 336 S.
ISBN 978-3-7983-2444-2 (print) EUR 5,00
ISBN 978-3-7983-2445-9 (online)
- 22: Rief, Daniel: Markteintritt in China.** Flexibilität und Integration als Erfolgsfaktoren in einer dynamischen und komplexen Marktumgebung. - 2013. - XIX, 235 S.
ISBN 978-3-7983-2482-4 (print) EUR 20,90
- 23: Richter, Markus: Nutzenoptimierter RFID-Einsatz in der Logistik.** Eine Handlungsempfehlung zur Lokalisierung und Bewertung der Nutzenpotenziale von RFID-Anwendungen. - 2013. - XIX, 235 S.
ISBN 978-3-7983-2523-4 (print) EUR 21,90
ISBN 978-3-7983-2524-1 (online)
- 24: Huynh, Thu Hang: Beitrag zur Systematisierung von Theorien in der Logistik.** - 2013. - XVII, 429 S.
ISBN 978-3-7983-2610-1 (print) EUR 21,90
ISBN 978-3-7983-2611-8 (online)
- 25: Fontius, Jörn: Megatrends und ihre Implikationen für die Logistik.** Ableitung von Wirkungszusammenhängen. - 2013. - XVII, 217 S.
ISBN 978-3-7983-2634-7 (print) EUR 12,50
ISBN 978-3-7983-2635-4 (online)
- 26: Ouyeder, Ouelid: Strategien für eine nachhaltige Lieferantenentwicklung für die Beschaffung aus Emerging Markets.** - 2013. - X, 279 S.
ISBN 978-3-7983-2658-3 EUR 21,50
- 27: Steffens, Anja: Logistische Wandlungsbefähiger.** Entwicklung eines kontextbasierten Gestaltungsmodells für die industrielle Logistik. - 2014. - XIII, 284 S.
ISBN 978-3-7983-2682-8 EUR 15,50
- 28: Siegmann, Julian B.: Prozessinnovationen bei Logistikdienstleistungsunternehmen.** - 2015. - xxxviii, 245 S.
ISBN 978-3-7983-2737-5 (print) EUR 15,50
ISBN 978-3-7983-2738-2 (online)
- 29: Keitel, Sebastian: Auswirkungen disaggregierter Regulierung auf die Kapazität von Verkehrssektoren.** Eine wettbewerbstheoretische und empirische Untersuchung am Beispiel des Luftverkehrssektors. - 2015. - IX, 252 S.
ISBN 978-3-7983-2749-8 (print) EUR 15,50
ISBN 978-3-7983-2750-4 (online)
- 30: Campos, Juliana Kucht: Integrated Framework for Managing Sustainable Supply Chain Practices.** - 2015. - xii, 121 S.
ISBN 978-3-7983-2783-2 (print) EUR 10,50
ISBN 978-3-7983-2784-9 (online)
- 31: Spiegel, Timo U.: Technologieorientiertes Service Engineering in der Kontraktlogistik.** Konzeption eines Gestaltungsmodells für die systematische Entwicklung technologiebasierter Logistikdienstleistungen. - 2016. - x, 295 S.
ISBN 978-3-7983-2807-5 (print) EUR 15,50
ISBN 978-3-7983-2808-2 (online)

- 32: Figiel, Anna: Transportmanagement in der schnelldrehenden Konsumgüterindustrie.** Entwicklung eines Gestaltungsansatzes zur Integration von Transport und Logistik. - 2016. - XVIII, 227 S.
ISBN 978-3-7983-2816-7 (print) EUR 14,50
ISBN 978-3-7983-2817-4 (online)
- 33: Durach, Christian F.: A Theoretical and Practical Contribution to Supply Chain Robustness.** Developing a Schema for Robustness in Dyads. - 2016. - viii, 183 S.
ISBN 978-3-7983-2812-9 (print) EUR 13,50
ISBN 978-3-7983-2813-6 (online)
- 34: Blome, Hendrik: Logistische Optionen für eine nachhaltige Versorgung von Subsahara Afrika.** Ein Beitrag zur Humanitären Logistik. - 2016. - XVII, 315 S.
ISBN 978-3-7983-2840-2 (print) EUR 16,50
ISBN 978-3-7983-2841-9 (online)
- 35: Kucht Campos, Juliana: A methodology for planning sustainable supply chain initiatives.** - 2016. - xviii, 326 S.
ISBN 978-3-7983-2860-0 (print) EUR 16,50
ISBN 978-3-7983-2861-7 (online)
- 36: Wutke, Sebastian: Entwicklung eines Gestaltungsmodells zur Berücksichtigung von Nachhaltigkeit bei der Ausschreibung und Vergabe logistischer Leistungen im Straßengüterverkehr.** - 2017. - X, 299 S.
ISBN 978-3-7983-2862-4 (print) EUR 15,50
ISBN 978-3-7983-2863-1 (online)
- 37: Schöder, Dustin: Technisch-wirtschaftliche Bewertung des Einsatzes von batterieelektrischen Nutzfahrzeugen in der Distribution von Konsumgütern.** - 2017. - XV, 287 S.
ISBN 978-3-7983-2920-1 (print) EUR 15,50
ISBN 978-3-7983-2921-8 (online)
- 38: Roy, Daniel Thomas: Industrie 4.0 – Gestaltung cyber-physischer Logistiksysteme zur Unterstützung des Logistikmanagements in der Smart Factory.** - 2017. - XVI, 204 S.
ISBN 978-3-7983-2944-7 (print) EUR 14,50
ISBN 978-3-7983-2945-4 (online)
- 39: Ding, Feng: Developing e-commerce logistics in cross-border relation.** - 2018. - XV, 186 S.
ISBN 978-3-7983-2972-0 (print) EUR 14,50
ISBN 978-3-7983-2973-7 (online)
- 40: Nitsche, Benjamin: Development of an assessment tool to control supply chain volatility.** - 2019. - VII, 161 S.
ISBN 978-3-7983-3054-2 (print) EUR 12,50
ISBN 978-3-7983-3055-9 (online)
- 41: Mittag, Peter: Entwicklung eines anwendungsorientierten Gestaltungsansatzes zur Geschäftsmodellinnovation mithilfe von smarten Produkt-Service-Systemen.** - 2019. - XXXIII, 201 S.
ISBN 978-3-7983-3048-1 (print) EUR 14,00
ISBN 978-3-7983-3049-8 (online)
- 42: Reipert, Jan: Open Innovation in der Logistik – Entwicklung eines Gestaltungsmodells zum Aufbau eines offenen Innovationsmanagements in logistischen Dienstleistungsunternehmen.** - 2019. - X, 206, XLVIII S.
ISBN 978-3-7983-3062-7 (print) EUR 10,50
ISBN 978-3-7983-3063-4 (online)
- 43: Junge, Anna Lisa: Conceptualizing and capturing digital transformation's customer value – a logistics and supply chain management perspective.** - 2020. - 214 S.
ISBN 978-3-7983-3177-8 (print) EUR 15,50
ISBN 978-3-7983-3178-5 (online)
- 44: Wiederer, Christina: Overcoming logistics-related barriers to higher-value exports – A decision framework to identify policy measures.** - 2021. - XVI, 425 S.
ISBN 978-3-7983-3230-0 (print) EUR 16,50
ISBN 978-3-7983-3231-7 (online)
- 45: Verhoeven, Peter: Management model for social and environmental impact in logistics through blockchain technologies.** - 2022. - X, 184, XXIV S.
ISBN 978-3-7983-3250-8 (print) EUR 12,50
ISBN 978-3-7983-3251-5 (online)

Machine Learning im Logistikmanagement

Als ein Teilbereich der Künstlichen Intelligenz stellt Machine Learning (ML) eine Schlüsseltechnologie des 21. Jahrhunderts dar. Unter Nutzung der mathematisch-statistischen Verfahren sind Systeme realisierbar, die anhand von Daten eigenständig empirische Zusammenhänge erkennen und dadurch ihr Verhalten zur Lösung von betrieblichen Problemen im Sinne einer systemseitigen Lernfähigkeit anpassen können. Entsprechend der Komplexität von Planungs-, Steuerungs- und Kontrollaufgaben in industriellen Wertschöpfungsketten wird ML-Anwendungen eine hohe Bedeutung zur Unterstützung und autonomen Ausführung von logistischen Entscheidungsprozessen zugesprochen. Für diesen Bereich werden in der Dissertation unter Berücksichtigung des aktuellen Forschungsstands und mittels einer intensiven Einbeziehung der Praxis realisierbare Anwendungsmöglichkeiten, resultierende Auswirkungen und notwendige Voraussetzungen ermittelt. Das Ergebnis stellt einen Gestaltungsansatz dar, der Unternehmen geeignete Maßnahmen zum erfolgreichen Einsatz von ML im Logistikmanagement entlang mehrerer Handlungsfelder aufzeigt.

ISBN 978-3-7983-3297-3 (print)

ISBN 978-3-7983-3298-0 (online)



ISBN 978-3-7983-3297-3



<https://verlag.tu-berlin.de>