

Karlsruher Schriften
zur Anthropomatik

Band 57



Achim Christian Kuwertz

**Adaptive Umweltmodellierung für kognitive
Systeme in offener Welt durch dynamische
Konzepte und quantitative Modellbewertung**

Achim Christian Kuwertz

**Adaptive Umweltmodellierung für kognitive
Systeme in offener Welt durch dynamische Konzepte
und quantitative Modellbewertung**

Karlsruher Schriften zur Anthropomatik

Band 57

Herausgeber: Prof. Dr.-Ing. habil. Jürgen Beyerer

Eine Übersicht aller bisher in dieser Schriftenreihe
erschienenen Bände finden Sie am Ende des Buchs.

Adaptive Umweltmodellierung für kognitive Systeme in offener Welt durch dynamische Konzepte und quantitative Modellbewertung

von
Achim Christian Kuwertz

Karlsruher Institut für Technologie
Institut für Anthropomatik und Robotik

Adaptive Umweltmodellierung für kognitive Systeme in offener Welt
durch dynamische Konzepte und quantitative Modellbewertung

Zur Erlangung des akademischen Grades eines Doktors der Naturwissenschaften von der KIT-Fakultät für Informatik des Karlsruher Instituts für Technologie (KIT) genehmigte Dissertation

von Dipl.-Inform. Achim Christian Kuwertz

Tag der mündlichen Prüfung: 21. Dezember 2020

Erster Gutachter: Prof. Dr.-Ing. habil. Jürgen Beyerer

Zweiter Gutachter: Prof. Dr.-Ing. habil. Uwe D. Hanebeck

Impressum



Karlsruher Institut für Technologie (KIT)
KIT Scientific Publishing
Straße am Forum 2
D-76131 Karlsruhe

KIT Scientific Publishing is a registered trademark
of Karlsruhe Institute of Technology.
Reprint using the book cover is not allowed.

www.ksp.kit.edu



This document – excluding parts marked otherwise, the cover, pictures and graphs – is licensed under a Creative Commons Attribution 4.0 International License (CC BY 4.0):
<https://creativecommons.org/licenses/by/4.0/deed.en>



The cover page is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License (CC BY-NC 4.0):
<https://creativecommons.org/licenses/by-nd/4.0/deed.en>

Print on Demand 2022 – Gedruckt auf FSC-zertifiziertem Papier

ISSN 1863-6489

ISBN 978-3-7315-1219-6

DOI 10.5445/KSP/1000148667

Kurzfassung

Die Verwendung von technisch kognitiven Systemen, welche den Menschen bei der Ausführung von alltäglichen Aufgaben unterstützen, nimmt über die letzten Jahre stetig zu. Häufig müssen solche Systeme in der Lage sein, eine für ihre Aufgaben relevante Umgebung sensorisch erfassen und verarbeiten zu können. Zu diesem Zweck können sog. Umweltmodelle eingesetzt werden, deren Aufgabe eine konsistente Integration, Verwaltung und Bereitstellung erfasster Umgebungsinformationen ist. Ein Beispiel eines solchen Umweltmodells ist das sog. objektorientierte Umweltmodell, welches nach probabilistischen Prinzipien operiert und schritthaltend den Zustand einer beobachteten Umgebung darstellt. Diese sensorbasierte Beschreibung wird dabei durch ein semantisches Domänenmodell ergänzt, in welchem als Hintergrundwissen relevante Typen von Entitäten der Umgebung modelliert werden. Derartige Domänenmodelle werden im Allgemeinen zur Entwurfszeit eines Systems von Wissensingenieuren manuell erstellt. Sie beschreiben somit immer nur einen abgeschlossenen Teil einer Anwendungsdomäne.

In dieser Arbeit wird nun der Fall betrachtet, dass ein solch abgeschlossenes Domänenmodell für die Umweltmodellierung nicht mehr ausreichend ist und dynamisch erweitert werden muss. Dabei wird von einer offenen Welt ausgegangen, d. h. einer Umgebung, in welcher auch nicht im Domänenmodell beschriebene Entitäten beobachtet werden können. Zu diesem Zweck wird in dieser Arbeit der Ansatz einer adaptiven Umweltmodellierung definiert, welcher es einem Umweltmodell ermöglicht, dynamisch auf unvorhergesehene Entitäten reagieren zu können. In diesem Ansatz können Wissensmodelle adaptiv durch das Erlernen neuer Konzepte erweitert werden. Um eine adaptive Umweltmodellierung zu ermöglichen, werden in dieser Arbeit unterschiedliche Aspekte und Methoden der probabilistischen Informationsverarbeitung im objektorientierten Umweltmodell angepasst und erweitert.

Als Grundlage zur Repräsentation von neu gelernten Konzepten werden zunächst ein formales Metamodell und eine Kern-Ontologie definiert, welche die strukturierte Erweiterung eines Domänenmodells durch das Erlernen neuer Konzepte ermöglichen. Dabei muss im Besonderen die probabilistische Informationsrepräsentation des Umweltmodells beachtet werden, die eine Erweiterung von logisch orientierten Repräsentationsansätzen notwendig macht. Weiterhin wird ein probabilistischer Klassifikationsansatz vorgeschlagen, welcher beobachteten Entitäten ihre im Domänenmodell modellierten Typen unter Verwendung einer Wahrscheinlichkeitsverteilung zuordnet. Dieser Ansatz kann ebenfalls bei der Erkennung von unvorhergesehenen Entitäten genutzt werden.

Als Hauptbeitrag dieser Arbeit wird ein Ansatz zur adaptiven Verwaltung und Erweiterung von Domänenmodellen präsentiert. Eine solche Erweiterung soll dabei nach Prinzipien wie der Bedarfsgerechtigkeit und Relevanz von Modellanpassungen erfolgen. Um den Bedarf einer Modellanpassung in einem Umweltmodell feststellen zu können, werden in dieser Arbeit Bewertungsmaße definiert, welche zur Quantifizierung der Modellgüte in Bezug auf die beobachtete Umgebung dienen. Diesen Bewertungsmaßen liegt ein Ansatz auf Basis des Prinzips der minimalen Beschreibungslänge zu Grunde. Unter Verwendung dieser Bewertungsmaße wird ein algorithmisches Regelungsschema definiert, welches die bedarfsgetriebene Anpassung eines Domänenmodells an relevante unvorhergesehene Entitäten erlaubt. Dazu werden weitere Bewertungsmaße definiert, welche die Detektion, Relevanzbewertung und Gruppierung solcher Entitäten ermöglichen. Auf Basis einer relevanten Gruppe von Entitäten, die einen spezifischen, bisher nicht modellierten Typ repräsentiert, kann dann eine Modellanpassung erfolgen. Als ein weiterer Beitrag wird daher ein Ansatz zum Lernen und Generalisieren von probabilistischen Konzeptdefinitionen vorgeschlagen. Abschließend erfolgt eine Evaluation der vorgeschlagenen Ansätze und Bewertungsmaße als Nachweis ihrer grundsätzlichen Anwendbarkeit an einem abstrahierten Anwendungsszenario der humanoiden Robotik für eine Haushaltsumgebung. Insgesamt beschreibt diese Arbeit somit einen ersten, aber grundlegenden Schritt in Richtung einer adaptiven Umweltmodellierung.

Danksagung

Die vorliegende Dissertation entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Lehrstuhl für Interaktive Echtzeitsysteme (IES) des Karlsruher Instituts für Technologie (KIT) sowie am Fraunhofer-Institut für Optronik, Systemtechnik und Bildverarbeitung (IOSB) in der Abteilung Interoperabilität und Assistenzsysteme (IAS). Herrn Professor Dr.-Ing. Jürgen Beyerer, Inhaber des Lehrstuhls IES und Institutsleiter des Fraunhofer IOSB, danke ich für die wissenschaftliche Betreuung meiner Arbeit und die wertvollen Diskussionen und Anregungen zu dieser. Für die Übernahme des Korreferats danke ich Herrn Prof. Dr.-Ing. Uwe D. Hanebeck.

Meinen ehemaligen Kollegen am Lehrstuhl IES danke ich ebenfalls für die anregenden Diskussionen in den Vortragsrunden und auf den Sommerseminaren sowie für die kollegiale Zeit am Lehrstuhl.

Meinen Kollegen am Fraunhofer IOSB in der Abteilung IAS, insbesondere Herrn Dr.-Ing. Rainer Schönbein als Abteilungsleiter sowie Frau Jennifer Sander und Frau Barbara Essendorfer als meinen Gruppenleiterinnen im Verlauf dieser Arbeit, danke ich für die Schaffung der notwendigen Freiräume, die kollegiale Atmosphäre, moralische Unterstützung sowie die inhaltlichen Diskussionen z. B. zu Themen der Wissensmodellierung.

Für das Korrekturlesen von Teilen dieser Arbeit und wertvolle Hinweise dazu danke ich im Speziellen Herrn Dr.-Ing. Rainer Schönbein, Herrn Dr.-Ing. Mathias Ziebarth sowie Herrn Dr. rer. nat. Markus Spies.

Weiterhin danke ich auch meinen Eltern für die andauernde emotionale Unterstützung und ihr Verständnis sowie die finanzielle Unterstützung zur Ermöglichung meines Studiums.

Mein ganz besonderer und herzlicher Dank gilt Silke, die mich in dieser Zeit immer bedingungslos unterstützt hat und mir auch im Privaten die notwendigen Freiräume geschaffen hat. Ebenfalls gilt ihr mein großer Dank für das Korrekturlesen der gesamten Arbeit. Ohne deine Fürsorge wäre diese Arbeit nicht möglich gewesen.

Karlsruhe, im Juni 2020

Achim Kuwertz

Inhaltsverzeichnis

Kurzfassung	i
Danksagung	iii
Notation	xi
Symbole	xiii
1 Einleitung	1
1.1 Motivation	1
1.2 Ausgangssituation und Anwendungsbeispiel	3
1.3 Spezifische Zielsetzung und Forschungsfragen	5
1.4 Eigene Beiträge	7
1.5 Gliederung der Arbeit	9
2 Stand der Technik und Wissenschaft	11
2.1 Einordnung der Arbeit	12
2.2 Wissensrepräsentation für kognitive Systeme	15
2.2.1 Thematischer Rahmen bezüglich der objektorientierten Umweltmodellierung	15
2.2.2 Relationale Wissensrepräsentation	17
2.2.3 Semantische Wissensrepräsentation und Ontologien	26
2.2.4 Repräsentation probabilistischer Informationen	39
2.2.5 Zusammenfassung zur Wissensrepräsentation	48
2.3 Umweltmodellierung und Wissensmodelle	49

2.3.1	Andere Umweltmodelle	49
2.3.2	Existierende Wissensbasen und -modelle	55
2.3.3	Zusammenfassung zu existierenden Wissens- und Umweltmodellen	64
2.4	Umweltmodellierung für offene Welten	65
2.4.1	Konzeptlernen	66
2.4.2	Ontologie-Lernen	69
2.4.3	Kognitive Architekturen	71
2.4.4	Spezifische Ansätze	72
2.4.5	Zusammenfassung	74
2.5	Informationsdarstellung beim maschinellen Sehen	75
2.5.1	Darstellung von Objektmodellen	76
2.5.2	Lernen von Modellen für Objektklassen	82
2.5.3	Zusammenfassung zum maschinellen Sehen	84
2.6	Zusammenfassung	85
3	Adaptive Umweltmodellierung	87
3.1	Grundlagen der Umweltmodellierung	87
3.2	Adaptive Umweltmodellierung	89
3.2.1	Prinzipien für eine adaptive Umweltmodellierung	91
3.2.2	Aufgaben der adaptiven Umweltmodellierung	93
3.3	Zusammenfassung	95
4	Strukturierung und Repräsentation von Vorwissen	97
4.1	Anforderungen an die Repräsentation von Vorwissen	98
4.1.1	Allgemeine Anforderungen	98
4.1.2	Anforderungen an die Repräsentation von Unsicherheiten	100
4.1.3	Weitergehende Aspekte	102
4.2	Gewähltes Vorgehen zur Strukturierung von Hintergrundwissen	105
4.2.1	Bewertung der Stand-der-Technik Ansätze	106
4.2.2	Gewähltes Vorgehen	110

4.3	Metamodellierung	112
4.3.1	Grundlegende Darstellung von Attributen	114
4.3.2	Probabilistische Repräsentation von Attributwerten	118
4.3.3	Probabilistische Repräsentation von Beziehungen	121
4.4	Strukturierung der Konzepte des Hintergrundwissens	129
4.4.1	Wissensstrukturierung in DOLCE	131
4.4.2	Integration des Metamodells in DOLCE	133
4.4.3	Kern-Ontologie für die objektorientierte Umweltmodellierung	136
4.5	Erstellung von Domänenmodellen zur Kern-Ontologie	143
4.5.1	Relationale Modellierung	145
4.5.2	Probabilistische Modellierung einer Domäne	146
4.6	Wissensmodell für die Haushaltsumgebung	153
4.6.1	Modellentwurf	153
4.6.2	Umsetzung	159
4.7	Zusammenfassung	169
5	Probabilistische Informationsverwaltung in der Umweltmodellierung	171
5.1	Probabilistische Informationsverarbeitung	172
5.1.1	Grundlegendes Verarbeitungsschema	173
5.1.2	Formale Informationsrepräsentation	175
5.1.3	Informationsalterung	179
5.1.4	Beobachtungsmodell	185
5.2	Datenassoziation	188
5.2.1	Zustandsschätzung zur Beobachtungsintegration	190
5.2.2	Assoziation- und Existenzwahrscheinlichkeit	193
5.2.3	Erweiterung und Untersuchung der Datenassoziation	197
5.2.4	Alternativer Ansatz zur Assoziation	204
5.2.5	Demonstration der Datenassoziation	207

5.3	Informationsverwaltung	212
5.3.1	Verwaltung von Repräsentanten	213
5.3.2	Entfernen von Repräsentanten	219
5.3.3	Qualitätsprüfungen	222
5.3.4	Verwaltung von Relationen	223
5.3.5	Zeitlicher Ablauf	232
5.4	Speicherung von Erfahrungsinformationen	233
5.5	Weiterführende Aspekte der Informationsverwaltung	244
5.6	Zusammenfassung	244
6	Bayes'sche Repräsentant-zu-Konzept Zuordnung	247
6.1	Einführung und Motivation	247
6.1.1	Die Repräsentant-zu-Konzept Zuordnung als Klassifikationsaufgabe	248
6.1.2	Vorarbeiten zur Repräsentant-zu-Konzept Zuordnung	252
6.1.3	Motivation eines Bayes'schen Ansatzes für die Repräsentant-zu-Konzept Zuordnung	256
6.2	Herleitung	257
6.2.1	Attributbasierte Zuordnungswahrscheinlichkeiten	258
6.2.2	Kombination der Anteile	261
6.3	Umsetzung und erste Demonstration des Ansatzes	263
6.3.1	Aufwandsbetrachtung und Berechnungsaspekte	264
6.3.2	Demonstrationsszenario	266
6.3.3	Ergebnisse im Demonstrationsszenario	267
6.4	Erweiterung der Zuordnung durch Nutzung von A-priori-Wissen	268
6.4.1	Effekte der Normierung	269
6.4.2	Erweiterte Repräsentant-zu-Konzept Zuordnung	271
6.4.3	Evaluation der erweiterten Zuordnung	278
6.5	Zusammenfassung	279

7	Quantitative Modellbewertung	281
7.1	Gewähltes Vorgehen	282
7.1.1	Das Prinzip der minimalen Beschreibungslänge	282
7.1.2	MDL-basiertes Vorgehen	284
7.2	Grundlegender Ansatz	284
7.2.1	Einfacher MDL-Ansatz	285
7.2.2	MDL-basierter Ansatz zur quantitativen Modellbewertung	285
7.3	Modellkomplexität	286
7.3.1	Konzeptkomplexität	287
7.3.2	Attributkomplexität	288
7.4	Modellkorrespondenz	291
7.4.1	Kumulative Berechnung der Modellkorrespondenz	292
7.4.2	Individuelle Repräsentant-zu-Konzept Korrespondenz	293
7.4.3	Attributbasierte Korrespondenzwerte	294
7.5	Aufwandsbetrachtung	297
7.5.1	Diskretisierung stetiger Attribute	297
7.5.2	Aufwandsabschätzung der Modellkomplexitätsbewertung	298
7.5.3	Aufwandsabschätzung der Modellkorrespondenzbewertung	298
7.6	Demonstration und Evaluation	299
7.6.1	Modellkomplexität	300
7.6.2	Modellkorrespondenz	302
7.6.3	Evaluation an einem einfachen Beispielszenario	305
7.7	Zusammenfassung	309
8	Adaptive Verwaltung von Hintergrundwissensmodellen	311
8.1	Überblick	311

8.2	Detektion von schlecht beschriebenen Repräsentanten . . .	313
8.2.1	Globale Ansätze zur Detektion	314
8.2.2	Lokale Ansätze zur Detektion	316
8.2.3	Untersuchung und Erweiterung des zuordnungsbasierten Detektionsmaßes	320
8.2.4	Evaluation	325
8.3	Adaptive Verwaltung von Hintergrundwissen	326
8.3.1	Regelschleife der adaptiven Modellverwaltung . . .	327
8.3.2	Auswahl relevanter Lernkandidaten	331
8.3.3	Durchführung von Modellanpassungen	334
8.4	Lernen probabilistischer Konzepte	337
8.4.1	Allgemeines Vorgehen	338
8.4.2	Lernen von Konzeptdefinitionen aus Beispielen . .	339
8.4.3	Generalisierung von Konzept-Attributen	340
8.5	Evaluation des Gesamtansatzes	350
8.5.1	Evaluationsszenario	350
8.5.2	Ergebnisse	358
8.6	Zusammenfassung	364
9	Zusammenfassung und Ausblick	365
9.1	Zusammenfassung	365
9.2	Ausblick	367
	Literatur	369
	Eigene Publikationen	395
	Abbildungsverzeichnis	399
	Tabellenverzeichnis	403
	Abkürzungsverzeichnis	405

Notation

Nachfolgend ist die in dieser Arbeit verwendete Notation dargestellt.

Allgemein

x	Skalare Variable
\mathbf{x}	Zufallsvariable
\hat{y}	Realisierung einer Zufallsvariable
\underline{x}	Vektor
$\underline{\mathbf{x}}$	Zufallsvektor
\mathbf{H}	Matrix
\mathcal{A}	Menge
$p(\cdot)$	Wahrscheinlichkeitsverteilung (Zähldichte, Dichtefunktion)
$p(\cdot \cdot)$	Bedingte Verteilung (Zähldichte, Dichtefunktion)

Indizierung

i, j	Indices, z. B. für Attribute a^i oder Repräsentanten r_j
r, r_i, r_j	Repräsentant als Index, z. B.: $c^r, a^{r,i}, d^r, E^{r,j}$ oder \underline{e}_k^r
k, k_0	Index für Zeitschritte, z. B.: $t_k, a_k^i, E_{k-1}^r, \hat{y}_{1:k-1}$ oder $k = 1$
n, n_a, s	Index für Anzahlen, z. B.: $a^{r,n}, \omega_{n_a}, \hat{y}^s$

Operatoren

\bar{E}	Komplement eines wahrscheinlichkeitstheoretischen Ereignisses
$ \cdot $	Kardinalität einer Menge
\sim	proportional (Beispiel: $x \sim y$)

Zahlenwerte

2.72	Dezimalzahlen werden nach Konvention in der Informatik [Goo00] und aus Gründen der Lesbarkeit mit einem Dezimalpunkt angegeben.
------	---

Symbole

Nachfolgend sind die in dieser Arbeit verwendeten Symbole dargestellt.

c	Konzept im Hintergrundwissen \mathcal{C}_0 oder \mathcal{C}
r	Repräsentant des Weltmodells \mathcal{R}
a	Attribut eines Konzepts c oder Repräsentanten r
$\mathcal{C}_0, \mathcal{C}$	Hintergrundwissen (als Menge)
\mathcal{R}	Weltmodell (als Menge)
s, s^*	schlecht beschriebener Repräsentant
$\mathcal{S}_{\mathcal{R}}$	Menge bzw. Liste von schlecht beschriebenen Repräsentanten
t_k	diskreter Zeitschritt
E, D	Ereignisse (wahrscheinlichkeitstheoretisch)
$\beta, \gamma, \tau, \Phi$	Parameter, Schwellwerte etc.
$w; z$	Gewichtung; Normierungskonstante
$Q(\cdot), L(\cdot)$	Maße für Modellgüte
$M(\cdot)$	Detektionsmaße für schlecht beschriebene Repräsentanten
Δ	kleinster unterscheidbarer Betrag (einer Größe)

$\mathcal{N}(\mu, \sigma^2)$	Normalverteilung mit Erwartungswert μ und Standardabweichung σ – Beispiel: $\mathcal{N}(0, 1^2)$
$H(\cdot)$	Shannon'sche Entropie
$D(\cdot \cdot)$	Kullback-Leibler Divergenz
d	Differential (Beispiel: dx)
\mathbb{N}, \mathbb{Z}	Natürliche und ganze Zahlen
\mathbb{Q}, \mathbb{R}	Rationale und reelle Zahlen

1 Einleitung

1.1 Motivation

In vielen Bereichen und Anwendungen nimmt über die letzten Jahre der Einsatz von technisch kognitiven Systemen zu, welche den Menschen bei alltäglichen Aufgaben unterstützen. Derartige Systeme reichen in ihrer Bandbreite von Assistenz- und Überwachungssystemen, wie sie z. B. in der Pflege oder im Bereich der Sicherheit eingesetzt werden, über Assistenzfunktionen im Bereich des unterstützten Fahrens bis hin zur Servicerobotik, wo z. B. Roboter Alltagsaufgaben übernehmen. Zur Erfüllung solcher Unterstützungsfunktionen müssen kognitive Systeme in der Lage sein, eine für ihre Aufgaben relevante Umgebung sensorisch erfassen, verarbeiten, interpretieren und speichern zu können. Dabei muss sowohl der Zustand einer Umgebung erfasst als auch dessen Bedeutung für den menschlichen Alltag adäquat interpretiert und verstanden werden. Zu diesem Zweck können sog. Umweltmodelle eingesetzt werden. Zu den Aufgaben der Umweltmodellierung¹ zählt dabei die konsistente Integration und Verwaltung erfasster Informationen, deren Verknüpfung mit Hintergrundwissen sowie deren anschließende bedarfsgerechte Bereitstellung an andere Komponenten eines technisch kognitiven Systems.

Sollen aufgrund eines erfassten Umgebungszustandes (semi-) automatisiert Entscheidungen getroffen oder Handlungen abgeleitet werden, so ist es essentiell, dass die Bedeutung von beobachteten Objekten und Ereignissen sowie die Beziehungen zwischen diesen formal repräsentiert werden, z. B. unter Verwendung eines Wissensmodells. Eine solche Anforderung ergibt sich

¹ auch als Welt-, Umfeld- oder Umgebungsmodellierung bezeichnet

für verschiedene technisch kognitive Systeme, darunter kognitive Assistenzsysteme zur Entscheidungsunterstützung sowie Serviceroboter.

Die Erstellung solcher Wissensmodelle ist ein zeitaufwendiger Prozess, der von Wissensingenieuren in Zusammenarbeit mit Domänenexperten durchgeführt wird. Heutzutage kann dieser Prozess durch Werkzeuge unterstützt werden. Sollen allerdings bestimmte Qualitätsanforderungen eingehalten werden, wie z. B. die Konsistenz, Nachvollziehbarkeit oder Erweiterbarkeit eines Wissensmodells, so ist dieser Prozess weiterhin mit manuellem Aufwand verbunden. Erstellte Domänenmodelle sind, aufgrund verschiedener Bedingungen, in ihrem Umfang endlich. Einer der Gründe ist der Zeitaufwand ihrer Erstellung, weitere Gründe sind u. a. der gewählte Fokus eines Modells sowie vorab verfügbare Informationen. Jedes Modell ist somit seiner Natur nach abgeschlossen. Dies steht in vielen Anwendungsbereichen von technisch kognitiven Systemen einer prinzipiell offenen, sich verändernden Welt gegenüber. Auch wenn nur ein bestimmter Ausschnitt der Welt in einer Anwendungsdomäne betrachtet wird, so besteht die Möglichkeit, dass zu einem Zeitpunkt Objekte oder Ereignisse auftreten und erfasst werden, welche nicht in einem Wissensmodell beschrieben sind.

Um einem technisch kognitiven System einen geordneten Umgang mit einer solchen Situation zu ermöglichen, beschäftigt sich diese Arbeit mit der Thematik einer adaptiven Umweltmodellierung für offene Welten. Die adaptive Umweltmodellierung soll es dabei ermöglichen, existierende Wissensmodelle bei Bedarf an die erfassten Umgebungsbedingungen anzupassen, indem diese Wissensmodelle nach bestimmten Prinzipien um neue, dynamisch definierte Konzepte erweitert werden. Grundlage einer solchen Anpassung ist dabei die quantitative Bewertung von Wissensmodellen in Bezug auf ihre Fähigkeit, die aktuell in einer Umgebung beobachteten Entitäten beschreiben zu können.

1.2 Ausgangssituation und Anwendungsbeispiel

Der in dieser Arbeit erweiterten Umweltmodellierung liegt ein spezifischer Ansatz zu Grunde. Ausgangspunkt sind die objektorientierte Umweltmodellierung [Bey07] und die Ansätze des in Abbildung 1.1 dargestellten objektorientierten Umweltmodells (OOWM) [Emt08, Bau09, Ghe10b, Hei10]. Dieser Ansatz beschreibt ein domänen-agnostisches Vorgehen zur Umweltmodellierung, in welchem aktuelle Zustandsinformationen über eine betrachtete Umgebung repräsentiert und mit einem semantischen Wissensmodell verknüpft werden. Der Fokus liegt dabei auf der Repräsentation der relevanten Objekte einer betrachteten Domäne. Das objektorientierte Umweltmodell dient als Gedächtnismodell oder Informationsdrehscheibe innerhalb von technisch kognitiven Systemen. Die Verarbeitung und Repräsentation von Informationen folgt dabei den Prinzipien einer probabilistischen Informationsverarbeitung. Dies resultiert aus dem Grundsatz der objektorientierten Umweltmodellierung, auftretenden Unsicherheiten explizit Rechnung tragen zu können. Solche Unsicherheiten können z. B. bei der messtechnischen Erfassung von Objekten und ihrer Eigenschaften durch Sensoren entstehen, ebenso bei der Verarbeitung von Informationen sowie bei der Modellierung von Vorwissen. Objekte werden dabei mittels probabilistischer Attribute im Umweltmodell repräsentiert, welche die durch Sensoren beobachteten Eigenschaften beschreiben. Diese Objekte werden mit einem semantischen Wissensmodell verknüpft, für welches in der objektorientierten Umweltmodellierung eine manuelle Erstellung durch Wissensingenieure angenommen wird. Da die objektorientierte Umweltmodellierung zur Anwendung in verschiedenen Domänen konzipiert ist, muss auch die zu entwickelnde adaptive Umweltmodellierung für offene Welten domänen-agnostisch entworfen werden. Weiterhin muss in dieser Arbeit die probabilistische Informationsdarstellung und -verarbeitung beachtet werden.




Abbildung 1.1: Überblick über die objektorientierte Umweltmodellierung. Das Umweltmodell besteht aus den beiden Anteilen Weltmodell und Hintergrundwissen. Im Weltmodell werden Objekte der realen Welt durch Repräsentanten (Rep1, Rep2 etc.) dargestellt. Im Hintergrundwissen werden Typen von Objekten durch hierarchisch geordnete Klassen modelliert.

Abbildung 1.1 stellt das objektorientierte Umweltmodell als eine Komponente im Überblick dar. Es besteht dabei auch aus zwei Anteilen: Das Weltmodell ist dabei zuständig für die Repräsentation des aktuellen Umgebungszustandes, das Hintergrundwissen stellt formalisiertes Vorwissen bzgl. der Domäne bereit und definiert somit die Semantik der im Weltmodell repräsentierten Informationen. Beobachtete Informationen bzgl. des betrachteten Ausschnitts der realen Welt werden durch Sensoren erfasst. Im Weltmodell findet eine objektorientierte Fusion dieser Informationen statt, welche potenziell aus heterogenen Quellen stammen können.

Die objektorientierte Umweltmodellierung abstrahiert dabei heterogene Sensordaten explizit zu einer einheitlichen und integrierten Darstellung der enthaltenen Informationen im Weltmodell. Diese werden in Form von Attributen dargestellt, welche beobachtete Eigenschaften von Objekten probabilistisch beschreiben. Informationen im Weltmodell werden schritt haltend mit neuen Sensordaten aktualisiert. Vorherige Umgebungszustände werden dabei in einer Zustandshistorie persistiert.

Die im Hintergrundwissensmodell enthaltenen Informationen dienen dazu, zusätzliche, z. B. mittels der Sensorik nicht beobachtbare Fakten und Zusammenhänge bereitzustellen und Schlussfolgerungen ziehen zu können. Dieses

verknüpfte Wissen wird schließlich für weitere Komponenten eines technisch kognitiven Systems, z. B. für eine Situationsanalyse, vom objektorientierten Umweltmodell zur Verfügung gestellt. Um die im Weltmodell repräsentierten Objekte mit entsprechenden Klassen im Hintergrundwissen verknüpfen zu können, werden die Objekte mittels eines probabilistischen Ansatzes klassifiziert.

Das objektorientierte Umweltmodell ist zur Anwendung in unterschiedlichen Domänen konzipiert und wurde bisher z. B. zur Unterstützung von Situationsbewusstsein in Überwachungssystemen [Bau09, Fis16] oder im Bereich der Servicerobotik [Bel17] eingesetzt. Die in dieser Arbeit entwickelten Methoden zur Erweiterung des objektorientierten Umweltmodells für offene Welten sind ebenfalls domänen-agnostisch konzipiert. Um die Anwendbarkeit der Methoden zu demonstrieren und auch durch konkrete Anwendungen zu veranschaulichen, werden an passenden Stellen Anwendungsbeispiele gegeben. Diese Anwendungsbeispiele entstammen dabei dem Bereich der humanoiden Servicerobotik und nutzen ein häufiges Anwendungsszenario, in welchem ein kognitives System bei der Ausführung von häuslichen Alltagsaufgaben unterstützen soll.

1.3 Spezifische Zielsetzung und Forschungsfragen

Das Ziel dieser Arbeit ist die Erweiterung des Ansatzes der objektorientierten Umweltmodellierung für offene Welten. Dabei soll die Umweltmodellierung in die Lage versetzt werden, mit unvorhergesehenen Arten von Objekten umgehen und sich bedarfsgerecht an diese anpassen zu können, indem neue Konzepte erlernt und in das genutzte Hintergrundwissensmodell aufgenommen werden. In bisherigen Arbeiten zum objektorientierten Umweltmodell wurden vor allem die Weltmodell-Komponente und ihre probabilistische Informationsverarbeitung detailliert betrachtet. Die Hintergrundwissens-Komponente wurde allgemein beschrieben und nur bzgl. einzelner Aspekte beispielhaft umgesetzt. Um ein domänen- und

anwendungsunabhängiges Vorgehen zur Erweiterung von Hintergrundwissensmodellen entwerfen und umsetzen zu können, muss zunächst dessen allgemeine Struktur prinzipiell und formal festgelegt werden. Dies definiert das Grundgerüst, innerhalb welchem ein Wissensmodell angepasst und neue Konzepte gelernt werden können. Als erste Fragestellung wird somit betrachtet,

- auf welche Weise ein Hintergrundwissensmodell für die objektorientierte Umweltmodellierung strukturiert, organisiert, und repräsentiert werden kann. Dabei müssen auch die Anforderungen, die in Vorarbeiten an das Hintergrundwissen gestellt wurden, beachtet werden.

Auf Basis einer entsprechenden Festlegung kann dann die übergeordnete Forschungsfrage betrachtet werden,

- wie eine bedarfsgerechte, nachvollziehbare Anpassung eines Hintergrundwissensmodells durch das Erlernen neuer relevanter Konzepte auf Basis von Beispielen erfolgen kann.

Dabei wird die Situation als Ausgangspunkt angenommen, dass im Betrieb des objektorientierten Umweltmodells Objekte in der betrachteten Umgebung beobachtet werden, für welche bisher keine Klassen im Hintergrundwissensmodell hinterlegt sind. Diese Situation stellt den Treiber dar, welcher Anpassungen im Wissensmodell veranlasst. Dabei ist es eine der Anforderungen an eine adaptive Umweltmodellierung, dass solche Anpassungen bedarfsgerecht erfolgen. Eine weitere Anforderung ist, dass nur relevante neue Konzepte in das Hintergrundwissensmodell übernommen werden. Beide Anforderungen sind aus menschlichen Erfahrungswerten motiviert und dienen dazu, unkontrollierte bzw. hochfrequente Anpassungen zu vermeiden und eine gewisse Steuerbarkeit und Nachvollziehbarkeit in die adaptive Umweltmodellierung aufzunehmen.

Als eine Randbedingung muss dabei davon ausgegangen werden, dass für das Erlernen neuer Konzepte nur eine relativ geringe Menge von Lernbeispielen zur Verfügung steht, nämlich die bisher beobachteten Objekte.

Die zuvor genannte übergeordnete Forschungsfragestellung kann somit in folgende Teilfragen aufgeteilt werden:

- Wie lässt sich der Bedarf für die Anpassung des Hintergrundwissensmodells beschreiben und erfassen? Dabei besteht auch ein Bezug zu den im Weltmodell repräsentierten Entitäten. Wie kann weiterhin quantitativ bewertet werden, wann Bedarf für eine Anpassung des Hintergrundwissensmodells besteht?
- Wie wird erkannt, welche im Weltmodell repräsentierten Entitäten bisher keinem der modellierten Konzepte des Hintergrundwissens zugeordnet werden können?
- Wie kann bewertet werden, dass ein Typ bisher nicht modellierter Entitäten relevant für eine Aufnahme ins Hintergrundwissen ist?
- Wie kann auf Basis von wenigen Beispielen solcher Entitäten ein generalisierendes Konzept für das Hintergrundwissen gelernt werden?
- Wie kann ein neu gelerntes Konzept in ein potenziell hierarchisches Hintergrundwissensmodell eingeordnet werden und wie können weitere, nicht aus Sensordaten ableitbare Eigenschaften für dieses Konzept gelernt werden?

Diese Fragestellungen werden in dieser Arbeit betrachtet. Ziel ist es dabei, Verfahren und Gütemaße zu entwickeln, mit deren Hilfe Antworten auf die genannten Fragen gegeben und Lösungen demonstriert werden können.

1.4 Eigene Beiträge

Die Beiträge dieser Arbeit lassen sich unterscheiden in Anteile, die direkt Verfahren für eine adaptive Umweltmodellierung betreffen, und solche, welche zur Ermöglichung der Ersteren die objektorientierte Umweltmodellierung wo notwendig vervollständigen, anpassen und erweitern. Die Beiträge zur adaptiven Umweltmodellierung ergänzen die Forschung an Umweltmodellen dabei um neuartige Aspekte wie eine quantitative Qualitäts- bzw.

Nützlichkeitsbewertung für Wissensmodelle sowie deren adaptive Erweiterung durch das Erlernen neuer Objektklassen innerhalb des Rahmens der objektorientierten Umweltmodellierung. Diese Beiträge betreffen:

- ein Maß zur Bewertung der Qualität eines Wissensmodells in Bezug auf den aktuell im Weltmodell repräsentierten Umgebungszustand [Kuw13a, Kuw12a] (Kapitel 7),
- einen Ansatz zur adaptiven Anpassung von Wissensmodellen (Kapitel 8), mit den Anteilen:
 - verschiedene Maße zur Identifikation von schlecht durch ein Domänenmodell repräsentierten Objekten [Kuw13b, Kuw16],
 - ein Ansatz zur Beurteilung der Relevanz neuer Objektklassen von schlecht repräsentierten Objekten [Kuw14],
 - ein Verfahren zum Erlernen neuer probabilistischer Objektklassen aus beobachteten Objekten [Kuw13b, Kuw14].
- Ein zusätzlicher Beitrag ist die probabilistische Modellierung eines Evaluationsszenarios mit interpretierbaren Objektattributen [Kuw16] (Abschnitt 8.5.1).

Weiterhin wurde der Ansatz der objektorientierten Umweltmodellierung an vielen Stellen ergänzt, vervollständigt und erweitert. Die wesentlichen eigenen Beiträge betreffen hierbei:

- ein Metamodell zur strukturierten Informationsrepräsentation von Hintergrundwissen im objektorientierten Umweltmodell [Kuw13c, Bel12c] (Kapitel 4),
- erweiterte Formalisierung der mathematischen Repräsentation des objektorientierten Umweltmodells (z. B. [Kuw13a]) (Kapitel 5 & 7),
- neuartiger Ansatz für eine probabilistische Klassifikation von im Weltmodell repräsentierten Objekten [Kuw13b, Kuw16] (Kapitel 6),
- Erweiterung des Ansatzes [Bau10] zur Objektidentifikation (Datenassoziation) im objektorientierten Umweltmodell (Kapitel 5).

1.5 Gliederung der Arbeit

Diese Arbeit ist im Weiteren wie folgt gegliedert:

- Kapitel 2 ordnet die Anteile dieser Arbeit in unterschiedliche Themengebiete ein und gibt einen Überblick über den für diese Arbeit relevanten Stand von Technik und Wissenschaft in diesen Gebieten.
- Kapitel 3 präsentiert allgemein die Problemstellung und das Vorgehen der adaptiven Umweltmodellierung und gibt einen Überblick über die objektorientierte Umweltmodellierung.
- In Kapitel 4 wird die entwickelte allgemeine Struktur für Hintergrundwissensmodelle der objektorientierten Umweltmodellierung vorgestellt sowie als ein Beispiel für diese Struktur ein spezifisches Hintergrundwissensmodell für die Haushaltsdomäne.
- In Kapitel 5 wird detailliert auf die probabilistische Informationsverarbeitung des objektorientierten Umweltmodells eingegangen.
- In Kapitel 6 wird die entwickelte probabilistische Repräsentant-zu-Konzept Zuordnung vorgestellt.
- Kapitel 7 stellt den entwickelten Ansatz zur quantitativen Bewertung eines Hintergrundwissensmodells in der Umweltmodellierung vor.
- Kapitel 8 präsentiert den übergeordneten Ansatz zur adaptiven Anpassung und Verwaltung eines Hintergrundwissensmodells.
- In Kapitel 9 wird die Arbeit schließlich zusammengefasst und ein Ausblick gegeben.

2 Stand der Technik und Wissenschaft

In diesem Kapitel wird zusammenfassend der für die vorliegende Arbeit relevante Stand der Technik und Wissenschaft dargestellt. Zusätzlich beinhalten einzelne Kapitel weitere Referenzen zu verwandten Ansätzen.

Die Umweltmodellierung zeichnet sich durch eine querschnittliche Natur aus. Umweltmodelle sind i. A. dafür ausgelegt, als eine Komponente innerhalb eines komplexeren Systems zu dienen und so in verschiedenen Anwendungsbereichen eingesetzt zu werden. Auch methodisch werden in der Umweltmodellierung Verfahren aus unterschiedlichen wissenschaftlichen und ingenieurstechnischen Themengebieten genutzt. In der vorliegenden Arbeit als einer Erweiterung der Umweltmodellierung ist diese querschnittliche Natur ebenfalls gegeben. Entsprechend werden Methoden und Verfahren aus unterschiedlichen Themengebieten betrachtet und eingesetzt. Dieses Kapitel legt den Stand der Technik und Wissenschaft nun für die relevanten Anteile dieser Themengebiete mit Bezug zur adaptiven Umweltmodellierung und zu Teilen der objektorientierten Umweltmodellierung dar. Vorausgehend wird zunächst eine thematische Einordnung dieser Arbeit und der adaptiven Umweltmodellierung im Speziellen vorgenommen.

2.1 Einordnung der Arbeit

Die adaptive Umweltmodellierung betrachtet die dynamische Repräsentation von Wissen bzgl. einer Domäne und der in ihr beobachteten Objekte. Dabei wird auf der probabilistischen Informationsdarstellung der objektorientierten Umweltmodellierung aufgesetzt und es werden Repräsentationen von Sensordaten zu symbolischem Wissen in Beziehung gesetzt. Adaptive Anpassungen an einem Wissensmodell erfordern weiterhin das Erlernen neuer Klassen aus wenigen Beispielen. Somit sind insgesamt die folgenden Themengebiete für die adaptive Umweltmodellierung bzgl. inhaltlicher Überschneidungen relevant:

- Wissensmodellierung und -repräsentation, inklusive Ansätzen zur logisch-probabilistischen Modellierung¹,
- Konzept- und Taxonomielernen, inklusive Aspekten aus kognitiven Architekturen,
- probabilistische Informationsverarbeitung und Zustandsschätzung
- sowie maschinelles Sehen.

Nachfolgend wird die adaptive und allgemeine Umweltmodellierung in Relation zu den genannten Themengebieten gesetzt und deren Relevanz für diese Arbeit zusammenfassend dargestellt.

Wissensmodellierung und -repräsentation Dieses Gebiet beschäftigt sich mit der Modellierung und formalen Repräsentation von Wissen über eine betrachtete Anwendungsdomäne. Dazu wird über eine Domäne vorhandenes Hintergrundwissen erfasst, analysiert, strukturiert und derart formal repräsentiert, dass es in Systemen gewinnbringend zur Anwendung gebracht werden kann. In der Umweltmodellierung werden gängige Ansätze der Wissensrepräsentation genutzt, um ein Umweltmodell mit relevantem Hintergrundwissen über die betrachtete Umgebung auszustatten. Abschnitt 2.2 stellt die Grundlagen dieses Gebiets dar und Abschnitt 2.3 betrachtet als

¹ Beinhaltet: prädikatenlogisch-probabilistische Sprachen, probabilistisch-relationale Modelle, statistisch-relationale Ansätze usw.

verwandte Ansätze existierende Modelle, welche bereits formalisiertes Wissen über bestimmte Anwendungsdomänen enthalten.

Logisch-probabilistische Modellierung In diesem Gebiet werden ebenfalls Domänenmodelle erstellt. Im Vergleich zur allgemeinen Wissensmodellierung liegt der Schwerpunkt der erstellten Modelle hier allerdings auf der Ermöglichung von probabilistischen Schlussfolgerungen. Zur Darstellung komplexer Domänen werden logikbasierte Repräsentationssprachen mit probabilistisch-graphischen Modellen kombiniert, wodurch die Berücksichtigung von Unsicherheiten ermöglicht wird. Ähnlich zur objektorientierten Umweltmodellierung verwenden viele Repräsentationssprachen einen objektbasierten Ansatz zur Domänenmodellierung. Die Darstellung von unsicherem Wissen in der logisch-probabilistischen Modellierung ist relevant für die objektorientierte Umweltmodellierung. Die Aspekte des probabilistischen Schlussfolgerns sind eher für der Umweltmodellierung nachgelagerte Komponenten relevant, z. B. eine Situationsanalyse. Das Themengebiet der logisch-probabilistischen Modellierung wird ebenfalls in Abschnitt 2.2 dargestellt.

Konzept- und Taxonomielernen Dies ist ein Thema, das allgemein für die Anpassung eines Hintergrundwissensmodells auf Basis von Beispieldaten relevant ist. Dabei sind mehrere Teilgebiete betroffen, wie etwa das klassische Konzeptlernen, konzeptuelles Clustern, die numerische Taxonomie, perzeptive Verankerung oder das textbasierte Lernen von Ontologien. Auf diese Aspekte wird in Abschnitt 2.4 eingegangen. Weiterhin finden sich Ähnlichkeiten auch im Gebiet der kognitiven Modellierung, speziell bei kognitiven Architekturen.

Kognitive Modellierung Dieses Forschungsgebiet beschäftigt sich mit der Erforschung und Modellierung von kognitiven Prozessen beim Menschen. Dabei werden auch computergestützte Modelle verwendet und entsprechend künstliche kognitive Systeme umgesetzt. Die betrachteten Problemstellungen ähneln in Teilen denen der Umweltmodellierung, nämlich beispielsweise die Fragestellungen, wie Umgebungsobjekte vom Menschen erfasst und repräsentiert werden, wie ihnen Bedeutung zugeordnet wird und wie allgemein das Ziehen von Schlussfolgerungen auf Basis

solcher Beobachtungen abläuft. Dabei stehen im Vergleich zur Umweltmodellierung andere Zielsetzungen im Vordergrund, wie das Verstehen von menschlichem Verhalten, so dass die genannten Aspekte rein als Teilprobleme und nur aus einer menschenzentrierten Perspektive betrachtet werden. Die genutzten Prinzipien können allerdings auch für die adaptive Umweltmodellierung nützlich sein und als Inspiration dienen. Dieses Themengebiet wird ebenfalls in Abschnitt 2.4 behandelt.

Probabilistische Informationsverarbeitung In der Umweltmodellierung muss der Zustand der über Sensoren wahrgenommenen Umgebung repräsentiert und schritthaltend mit neuen Beobachtungen mitgeführt werden. Dies ist Teil der probabilistischen Informationsverwaltung im Weltmodell der objektorientierten Umweltmodellierung. Weiterhin werden in der adaptiven Umweltmodellierung neue Konzepte aufgrund von probabilistisch repräsentierten Objektbeobachtungen gelernt. Hier werden Methoden zur Fusion und Vereinfachung von Wahrscheinlichkeitsverteilungen benötigt, welche die beobachteten Eigenschaften der Objekte unsicherheitsbehaftet repräsentieren. Relevante Methoden der probabilistischen Informationsverarbeitung werden in den nachfolgenden inhaltlichen Kapiteln jeweils direkt an den Stellen genannt, wo entsprechende Verfahren eingesetzt werden.

Maschinelles Sehen Das maschinelle Sehen stellt auf gewisse Weise ein verwandtes Themengebiet dar, welches in Teilen mit Aspekten der objektorientierten Umweltmodellierung konkurriert. Dies betrifft z. B. alternative Vorgehensweisen zur Identifizierung und Klassifikation beobachteter Objekte. Weiterhin stellt das Themengebiet ein methodisches Bindeglied zu bestimmten Anwendungsbereichen der objektorientierten Umweltmodellierung dar, wie z. B. zur Servicerobotik. Maschinelles Sehen beschäftigt sich u. a. mit der Erkennung von Objekten und Szenen in Bildern und Videosequenzen. Verfahren des maschinellen Sehens definieren den aktuellen Stand der Wissenschaft und Technik für Aufgaben der Objekterkennung. Somit sind sie auch für die sensorische Umgebungswahrnehmung innerhalb der

Umweltmodellierung relevant. Weiterhin verwenden einige moderne Ansätze des maschinellen Sehens auch eine attributbasierte Darstellung für beobachtete Objekte, welche für die Darstellung wahrgenommener Informationen im objektorientierten Umweltmodell interessant ist. Dies ist allerdings die Ausnahme, die meisten z. B. merkmalsbasierten Objektdarstellungen erfüllen nicht die Anforderung in der Umweltmodellierung nach einer Darstellung mittels semantisch interpretierbarer Objekteigenschaften. Auch weitere Aspekte der Umweltmodellierung, wie beispielsweise die Repräsentation von Objektzuständen oder eine Modellierung von Hintergrundwissen, stehen im Bereich des maschinellen Sehens nicht im Vordergrund. Auf relevante Teilaspekte des maschinellen Sehens wird in Abschnitt 2.5 eingegangen.

2.2 Wissensrepräsentation für kognitive Systeme

In diesem Abschnitt wird das Themengebiet der Wissensrepräsentation für kognitive Systeme dargestellt und der relevante Stand der Technik und Wissenschaft herausgearbeitet. Dies beinhaltet auch die Betrachtung von logisch-probabilistischen Modellen.

2.2.1 Thematischer Rahmen bezüglich der objektorientierten Umweltmodellierung

Bevor in den nächsten Abschnitten auf den relevanten Stand der Technik und Wissenschaft zur Wissensrepräsentation eingegangen wird, soll zunächst der thematische Rahmen, in welchem repräsentiertes Wissen in der objektorientierten Umweltmodellierung relevant ist, aufgezeigt werden.

Im objektorientierten Umweltmodell soll Vorwissen über eine Anwendungsdomäne repräsentiert werden. Dieses Vorwissen soll die für eine Anwendungsdomäne relevanten Objekte mittels ihrer relevanten Eigenschaften beschreiben. Interessierende Eigenschaften betreffen dabei z. B. die Erscheinung der Objekte, ihre physikalischen Eigenschaften oder ihren aktuellen

Zustand sowie ihre Beziehungen zu anderen Objekten. Weiterhin soll auch die Bedeutung der Objekte in der Anwendungsdomäne bzw. für die intendierte Anwendung des kognitiven Systems im Vorwissen repräsentiert werden, so dass ein kognitives System bei der Erfüllung seiner Aufgaben möglichst gut durch das Vorwissen unterstützt werden kann.

Dieses Vorwissen soll dabei objektorientiert strukturiert sein – d. h. relevante Objekte werden abstrahiert durch Klassen beschrieben. Auch unsicheres Wissen soll, in Form von Wahrscheinlichkeitsverteilungen, beschrieben werden können. Weiterhin muss eine semantische Beschreibung der Objekte ermöglicht werden. Neben Vorwissen müssen im objektorientierten Umweltmodell auch aktuelle Informationen über Objekte (z. B. ihren Zustand betreffend) dargestellt werden. Sofern diese Informationen aus Beobachtungen stammen (was im Allgemeinen angenommen wird), müssen diese ebenfalls als unsicherheitsbehaftet repräsentiert werden. Das objektorientierte Umweltmodell muss daher in der Lage sein, Zustandsinformationen probabilistisch darzustellen. Dieser Aspekt muss bei der Wahl eines Formalismus zur Wissensrepräsentation für die objektorientierte Umweltmodellierung entsprechend berücksichtigt werden. Der zur Repräsentation von Wissen verwendete Formalismus hat weiterhin Einfluss auf das Lernen neuer Konzepte, da diese ja innerhalb des Formalismus als Klassen mit entsprechenden Eigenschaften und Beziehungen repräsentiert werden müssen. Innerhalb dieses thematischen Rahmens sind daher folgende Bereiche der Wissens- und Informationsrepräsentation für diese Arbeit relevant:

- allgemeine Wissensrepräsentation, z. B. auf konzeptueller Ebene und mittels relationaler Strukturen und Logiken,
- semantische Wissensrepräsentation und Ontologien,
- probabilistische Informationsrepräsentation, z. B. anhand von Zustandsraummodellen und
- kombinierte Formalismen zur logisch-probabilistischen Darstellung von Wissen.

Relationale Formalismen eignen sich besonders, um die grundsätzliche Struktur einer Anwendungsdomäne repräsentieren zu können - im Sinne

von Klassen relevanter Objekte und deren Eigenschaften, taxonomischer Beziehungen zwischen diesen Klassen etc. Vorwissen auch über komplexe Domänen kann hierbei strukturiert, handhabbar und wiederverwendbar dargestellt werden [Kol98, Las08, How09].

Probabilistische Informationen sind häufig Ergebnisse von Messungen oder Schätzungen und werden als Zufallsvariablen modelliert. Oft müssen diese auch dynamisch aktualisiert werden, um z. B. schritthaltend den Zustand von veränderlichen Objekten darstellen zu können. Dabei müssen diskrete und stetige Zufallsvariablen dargestellt werden können. Gängige Verfahren (z. B. rekursive Bayes'sche Filterverfahren) verwenden zur Modellierung von Zufallsvariablen und ihrer probabilistischen Zusammenhänge oft Zustandsraummodelle. Zufallsvariablen werden hier zu Vektoren zusammengefasst und deren Wahrscheinlichkeitsverteilungen (approximativ) über parametrische Verteilungsannahmen repräsentiert.

Die Wissensrepräsentation im objektorientierten Umweltmodell erfordert sowohl eine strukturierte Repräsentation der Anwendungsdomäne als auch die Darstellung von probabilistischen Informationen. Daher müssen kombinierte Formalismen betrachtet werden, welche auch eine probabilistische Repräsentation von Informationen ermöglichen.

Zum Stand der Technik und Wissenschaft in diesem Bereich wird unter den genannten Aspekten in den nachfolgenden Abschnitten ein Überblick gegeben, zugeschnitten auf den genannten thematischen Rahmen der objektorientierten Umweltmodellierung.

2.2.2 Relationale Wissensrepräsentation

Eine grundlegende Form der Wissensrepräsentation orientiert sich an relationalen Strukturen. Verallgemeinert wird hier eine Anwendungsdomäne modelliert, indem die für die Domäne relevanten Entitäten (wie z. B. Objekte) samt deren Relationen untereinander erfasst sowie deren Attribute bestimmt werden. Ein abstraktes derartiges Modell wird auch als konzeptuelles Modell

der Anwendungsdomäne verstanden und kann mit entsprechenden Modellierungssprachen repräsentiert werden. Eine stärker formalisierte Repräsentation solcher Modelle ist z. B. über die Prädikatenlogik möglich. Logikbasierte Repräsentationen bieten i. A. den Vorteil, auch Mechanismen für das automatisierte Schlussfolgern bereitstellen zu können. Diese unterschiedlichen Aspekte der relationalen Wissensrepräsentation werden nachfolgend kurz dargestellt.

Konzeptuelle Modellierung

Die konzeptuelle Modellierung einer Anwendungsdomäne ist ein wichtiger Aspekt und Prozessschritt im Bereich der Softwareentwicklung. Die konzeptuelle Modellierung hat zum Ziel, die wichtigsten Begriffe und Objekte einer Domäne zu erfassen und ihre Beziehungen untereinander zu beschreiben. Der Zweck dieser Modellierung ist dabei, die sich anschließenden Phasen des Softwareentwicklungsprozesses durch ein gemeinsames Verständnis der Domäne zu unterstützen, z. B. in Form von vereinheitlichten Begriffen sowie einer Strukturierung der Domänen-Entitäten [Rob15].

Als grundlegendes Modell und allgemeine Modellierungssprache kann in diesem Bereich das Entity-Relationship (ER) Modell nach Chen [Che76] genutzt werden [Str13a]. Im ER-Modell werden Entitäten, d. h. identifizierbare Objekte der Anwendungsdomäne, sowie Beziehungen zwischen diesen modelliert. Gleichartige Entitäten werden zu Entitätstypen zusammengefasst, gleichartige Relationen zu Relationstypen. Entitäts- und Relationstypen werden über Attribute mit definierten Wertebereichen beschrieben. Relationen bzw. Relationstypen sind dabei nicht auf binäre Beziehungen beschränkt, d. h. es können Beziehungen zwischen mehr als zwei Entitätstypen bestehen. Weiterhin können Kardinalitäten für Relationen spezifiziert werden [Car11], welche angeben, wie viele konkrete Entitäten eines Typs an einer Relation teilnehmen dürfen. Erweiterungen des ER-Modells führen weitere Modellelemente ein (d. h. Modellierungsprimitive, die eine definierte Semantik innerhalb der Sprach von ER-Modelle besitzen): spezifische Beziehungen zwischen Entitätstypen wie Generalisierungs-

bzw. Spezialisierungsbeziehungen (sog. „is-a“ Beziehungen) sowie Teil-Ganzes-Beziehungen (sog. „part-of“ Beziehungen). Die Definition eines Domänenmodells erfolgt meist visuell mittels Diagrammen als graphenbasierte Darstellung. Insgesamt definiert das ER-Modell somit bereits die grundlegenden Elemente zur Modellierung einer Anwendungsdomäne.

Eine ebenfalls visuell orientierte Modellierungssprache, welche zur konzeptuellen Modellierung eingesetzt werden kann, ist die Unified Modelling Language (UML) [Rum04]. UML ist im Bereich der objektorientierten Entwicklung von Softwaresystemen etabliert und hier besonders für Entwurf und Modellierung eine der wichtigsten Sprachen. Sie stellt die Konsolidierung und Vereinheitlichung vorhergehender Ansätze im Bereich der objektorientierten Modellierung dar [Fet16]. Bezüglich einer konzeptuellen Modellierung unterstützt UML, ähnlich zum ER-Modell, ebenfalls u. a. Klassen mit Attributen, binäre Relationen (auch gerichtet), Kardinalitätseinschränkungen für Relationen, eine Generalisierungshierarchie der modellierten Klassen sowie mit Aggregation und Komposition spezielle Relationen für Teil-Ganzes-Beziehungen. Über Erweiterungen wie der Object Constraint Language (OCL) können zusätzliche Einschränkungen bzw. Zusammenhänge für und zwischen modellierten Klassen spezifiziert werden, wie Einschränkungen des Wertebereichs von Attributen, z. B. Nichtnegativität für ein quantitatives Attribut, oder Ordnungsrelationen zwischen den Werten von Attributen. Neben der konzeptuellen Domänenmodellierung bietet die Sprache auch Modellierungselemente für dynamische Aspekte wie beispielsweise der Modellierung von Ablaufsequenzen von Operationen oder Benutzerinteraktionen.

Das ER-Modell und UML sind wichtige Vertreter von konzeptuellen Modellierungssprachen. Daneben existieren weitere Ansätze, auf die hier aber nicht weiter eingegangen wird. Insgesamt sind konzeptuelle Modelle oftmals in visuell orientierten, semi-formalen Sprachen repräsentiert [Str13a], die eine objektorientierte Modellierung der Anwendungsdomäne unterstützen. Allerdings sind z. B. ER-Modell und UML nicht für die dynamischen Aspekte der Weltmodellierung konzipiert, wie beispielsweise die schritthalte Verwaltung von Instanzen zu den modellierten Klassen in Form einer

Wissensbasis [Zed13]. Auch besitzt UML keine modelltheoretische formale Semantik [Car11] und unterstützt somit kein logisches Schlussfolgern. Die inhärente Repräsentation probabilistischer Attribute ist im ER-Modell und in UML ebenfalls nicht vorgesehen.

Logikbasierte Modelle

Während die konzeptuelle Modellierung im Bereich der Softwareentwicklung eine große Rolle spielt, stellt die logikbasierte Wissensrepräsentation z. B. einen zentralen Baustein im Bereich der künstlichen Intelligenz dar, wo automatisiertes Schlussfolgern ein wichtiger Faktor ist. Als wichtigster Vertreter im Bereich der logikbasierten Modellierung ist die Prädikatenlogik zu nennen [Las08].

Die Prädikatenlogik stellt eine Erweiterung der Aussagenlogik dar, welche diese um eine innere Struktur ergänzt [Las08]. Diese Struktur ermöglicht u. a. eine auf gewisse Art objektorientierte Modellierung der Anwendungsdomäne. Die Aussagenlogik [Goo00] ermöglicht es, Aussagen wie „Die Tasse steht auf dem Tisch“ mittels binärer Variablen zu modellieren. Aussagen können wahr oder falsch sein, so dass jede binäre Variable den entsprechenden Wahrheitswert annehmen kann. Einzelne Aussagen können über logische Operatoren (sog. Junktoren) zu komplexen logischen Aussagen verknüpft werden, welche als Formeln bezeichnet werden. Dabei können ebenfalls einfache Regeln in Form von Formeln abgebildet werden. Somit lassen sich allgemeine Gegebenheiten, im Sinne eines Vorwissens, über eine Anwendungsdomäne als eine Menge von Formeln modellieren. Dabei wird davon ausgegangen, dass die modellierten Aussagen die Domäne auf eine axiomatische Weise beschreiben.

Sind konkrete Informationen über die Domäne verfügbar (z. B. auf Basis aktueller Beobachtungen), so kann anhand dieser Informationen den in den Formeln enthaltenen Variablen (zumindest teilweise) ein Wahrheitswert zugewiesen werden (als Variablenbelegung im Sinne einer aussagenlogischen Interpretation). Durch diese Zuweisung lassen sich konkrete Information der Anwendungsdomäne („Instanzwissen“) aussagenlogisch repräsentieren.

Auf dieser Basis ist nun einerseits zu prüfen, ob die konkreten Informationen zum Vorwissen konsistent sind, d. h. ob die modellierten Formeln unter der induzierten Interpretation erfüllt sind (mit Wahrheitswert wahr). Andererseits kann mittels logischen Schlussregeln per deduktiver Inferenz auf weitere geltende (wahre) Aussagen geschlussfolgert werden - und somit unter Verwendung von Vorwissen weitere Informationen gewonnen werden.

Die Prädikatenlogik (erster Ordnung) erweitert die Aussagenlogik um syntaktische Ausdrucksmächtigkeit und zusätzliche Prinzipien. Für die Modellierung einer Anwendungsdomäne sind dabei u. a. von Interesse [Goo00]:

- Variable Aussagen: Aussagen erhalten eine innere Struktur, indem sie nun von Variablen abhängen können – diese Aussagen werden dann als Prädikate bezeichnet.
 - Beispiel: Die aussagenlogische Aussage „Die Tasse ist weiß“ kann nun allgemeiner unter Verwendung eines Prädikats $W(x)$ mit der intendierten Bedeutung „ x ist weiß“ beschrieben werden.
- Variablen (wie in Prädikaten) beziehen sich auf Entitäten eines angenommenen Individuenbereichs, welcher die Menge aller im Modell betrachteten Entitäten beschreibt (unabhängig von deren Typ), beispielsweise „die Menge aller Gegenstände in einem Raum“.
- Quantifizierung von Aussagen: für mittels Variablen beschriebene Aussagen kann nun spezifiziert werden, ob sie für alle Entitäten gelten müssen oder für mindestens eine (beliebige) Entität – zu diesem Zweck werden Existenz- und All-Quantoren definiert.
 - Beispiele: „Es gibt mindestens eine weiße Tasse im Schrank S “ oder „Alle Tassen in Schrank S sind weiß“.
- Eigenschaften und Funktionen: über Funktionen können Eigenschaften (bzw. Werte dieser Eigenschaften) von Entitäten modelliert werden. Die Entitäten werden dabei (analog zum Vorgehen bei Prädikaten) als Variablen der Funktionen angegeben. Weiterhin lassen sich Entitäten über Funktionen auch durch ihre Beziehungen zu anderen Individuen beschreiben.

- Beispiel: „Ort von x “, „Durchmesser von x “, „Vater von x “.

Die Prädikatenlogik (im Folgenden ist immer die Prädikatenlogik erster Ordnung gemeint) ermöglicht es, strukturierte Aussagen über eine Anwendungsdomäne in Form von Formeln zu machen. Eine (prädikatenlogische) Formel besteht dabei aus Prädikaten, welche über Junktoren der Aussagenlogik verbunden sind. Die Variablen in Prädikaten können dabei über Quantoren gebunden werden. Neben Variablen können Prädikate auch auf Funktionen von Variablen (und, rekursiv, von Funktionen) definiert sein [Goo00]. Äquivalenzrelationen (z. B. Gleichheit) und Ordnungsrelationen können ebenfalls als Prädikate modelliert werden.

Zur Modellierung des Vorwissens für eine Anwendungsdomäne kann nun analog zum Vorgehen bei der Aussagenlogik eine Menge von Formeln angegeben werden, welche die Domäne axiomatisch beschreibt. Dabei können mittels Prädikaten Aussagen über bestimmte Teilmengen von Entitäten (im Sinne von Typen) formuliert werden, ähnlich zu objektorientierten Klassen. Im Unterschied zu Ansätzen der konzeptuellen Modellierung verfügt die Prädikatenlogik aber nicht über explizite Relationen mit spezifischer Semantik wie beispielsweise hierarchische „is-a“ Beziehungen. Diese müssen somit für jede Domäne eigens modelliert werden.

Die Prädikatenlogik besitzt mit der modelltheoretischen Semantik [Goo00] eine formale Semantik, welche ein erstelltes Domänenmodell, d. h. eine Formelmenge, mengenbasiert interpretiert. Jedem domänenspezifischen Sprachelement (Prädikate und Funktionen) wird dabei eine Bedeutung zugewiesen. Dazu muss zunächst ein konkreter Individuenbereich spezifiziert werden, das sog. Universum. Konstanten und freie Variablen müssen anschließend auf Entitäten aus diesem Universum abgebildet werden. Für Prädikate muss festgelegt werden, für welche Entitäten aus dem Universum sie den Wahrheitswert wahr annehmen und für welche den Wert falsch. Dies kann in Form von Teilmengen des Raums erfolgen, der sich als das kartesische Produkt über den Variablen eines Prädikats ergibt (d. h. als eine mathematische Relation). Für Funktionen muss festgelegt werden, auf welche Weise sie zwischen den Entitäten des Universums abbilden. Diese Festlegungen insgesamt werden als eine Interpretation der Formelmenge

bezeichnet. Sind dabei unter einer Interpretation alle Formeln erfüllt, so handelt es sich bei dieser um ein sog. Modell für die Formelmenge. Die Interpretation mit ihrem Universum beschreibt in diesem Fall eine sog. mögliche Welt für die modellierte Formelmenge.

Im Falle der Wissensmodellierung für eine Domäne mittels Prädikatenlogik wird meistens bereits während der Spezifikation der Formelmenge implizit von einem bestimmten Universum und einer intendierten Interpretation der Formelmenge ausgegangen. Trotzdem kann das erstellte Domänenmodell auch anders interpretiert werden, d. h. beispielsweise auf ein anderes Universum abgebildet werden. Mit Hilfe von Konstanten (nullstelligen Funktionen) können in der Prädikatenlogik bereits Aussagen über bestimmte konkrete Entitäten einer Anwendungsdomäne getroffen werden (eine entsprechende Interpretation implizit vorausgesetzt), so dass nicht nur Vorwissen auf der Ebene von Klassen a priori modelliert werden kann, sondern auch Instanzwissen, d. h. Informationen über konkrete Entitäten der Domäne. Auf diese Weise kann in der Prädikatenlogik auch fortlaufend eine Wissensbasis repräsentiert werden.

Gegenüber einer objektorientierten Modellierung mittels UML ist ein prädikatenlogisches Modell einer Domäne allerdings deutlich schwieriger handzuhaben (in Bezug auf Aspekte wie Erstellung, Wartung etc.), vor allem auch deswegen, weil die Prädikatenlogik nicht explizit für diesen Anwendungszweck entwickelt wurde [Isr83]. Eine Möglichkeit, intuitiver verwaltbare Domänenmodelle zu erstellen, liegt in der Verwendung von sog. frame-basierten Ansätzen zur Domänenmodellierung, welche nachfolgend beschrieben werden.

Die formale Semantik ermöglicht der Prädikatenlogik die Verwendung von deduktiver Inferenz, um nur implizit in einer Formelmenge enthaltene Informationen explizit darstellen und nutzen zu können. Ebenso können hiermit Widersprüche im Domänenmodell aufgedeckt werden, z. B. wenn dieses durch eine nicht erfüllbare Menge von Formeln repräsentiert wird. Inferenz in Prädikatenlogik ist korrekt und vollständig (die Ergebnisse einer Inferenz übertragen sich somit auf die Interpretationen der Formelmenge), allerdings i. A. nicht entscheidbar (d. h. es kann nicht notwendigerweise in

endlicher Zeit festgestellt werden, ob sich eine gegebene Formel aus einer Formelmenge ableiten lässt) [Goo00]. Um sowohl Entscheidbarkeit als auch effektive Berechenbarkeit, im Sinne einer Beschränkung der Worst-Case-Komplexität bzw. erwarteten Laufzeit, erreichen zu können, lassen sich syntaktische Teilmengen der Prädikatenlogik bilden, welche die zulässigen Sprachkonstrukte zur Domänenmodellierung entsprechend einschränken. Nachfolgend wird auf Beschreibungslogiken, welche solche Teilmengen darstellen, genauer eingegangen.

Frame-basierte Modellierung

Historisch gab es im Bereich der künstlichen Intelligenz (KI) verschiedene Richtungen bzgl. der Fragestellung, auf welche Art und Weise Wissen für kognitive Systeme repräsentiert werden sollte. Dabei stand z. B. eine mathematisch formale Richtung, welche auf Logiken als Mittel der Repräsentation setzte, gegenüber einer weiteren Richtung, welche sich bzgl. der Wissensrepräsentation stark an der Vorstellung orientierte, wie menschliche Denkprozesse ablaufen [Isr83]. Ein Vertreter dieser letzteren Richtung ist mit dem Konzept der sog. Frames gegeben. Frames in ihrer Grundform nach Minsky [Min74] ermöglichen es, Vorwissen über prototypische Situationen in einer Datenstruktur zu repräsentieren. Dieses Vorwissen soll den Kontext liefern, der einem kognitiven System den Umgang mit einer vorliegenden Situation ermöglicht. Dazu stellen Frames in sog. Slots vorbelegte Standardwerte für ihre Attribute bereit. Diese Slots können sowohl Daten als auch Verknüpfungen zu weiteren, untergeordneten Frames enthalten. Attributwerte in Slots können durch beobachtete Informationen ergänzt, konkretisiert oder überschrieben werden. Über die Verknüpfungen kann zwischen Frames navigiert werden, um z. B. ähnliche oder spezifischere Situationen auffinden oder auch mögliche, auf die aktuelle Situation nachfolgende Situationen vorhersagen zu können. Frames ermöglichen es weiterhin auch anzugeben, unter welchen Bedingungen ein Frame überhaupt angewendet werden kann. Frames stellen eine Version von semantischen Netzen dar [Rus10].

Zur konkreten Wissensrepräsentation im Bereich der KI werden sog. frame-basierte Repräsentationssysteme eingesetzt. Diese setzen das von Minsky beschriebene Frame-Konzept in Form von Repräsentationssprachen um, welche eine konzeptuelle Modellierung ermöglichen. Im Bereich der KI sind dabei häufig umfangreiche, komplexe, aber strukturierte Anwendungsdomänen zu modellieren. Vor dem Aufkommen der Idee des Semantic Web stellten frame-basierte Repräsentationssysteme den Stand der Technik zur Wissensrepräsentation in der KI dar [Kol98]. Sie zeichnen sich durch ein strukturiertes Vorgehen und eine modulare Wissensorganisation aus [How09] und stellen somit z. B. intuitiver handhabbare Wissensmodelle dar als eine entsprechende prädikatenlogische Repräsentation.

Frames werden dabei als eine Datenstruktur umgesetzt, welche alles relevante Wissen zu einem Kontext (einer Situation, einem Objekt etc.) zusammengefasst repräsentiert. Die Frames entsprechen somit instanzitierbaren Klassen, welche hierarchisch angeordnet sein können. Die Eigenschaften eines Frames werden wie oben erwähnt über Slots beschrieben [How09]. Einfache Slots stellen Werte dar, während komplexe Slots auf andere Frame-Instanzen verweisen. Neben einer statischen Beschreibung des modellierten Kontexts ermöglichen Frames auch die Modellierung prozeduralen Wissens: mit Slots können sog. Trigger verbunden sein, die bei ihrer Auslösung eine definierte Prozedur abarbeiten.

Frame-basierte Repräsentationssysteme stellen die intuitive Modellierung einer Anwendungsdomäne in den Vordergrund. Oft besitzen die entsprechenden Sprachen keine inhärente formale Semantik. Zum Teil wurde dieser Aspekt nachgelagert betrachtet, z. B. durch das Abbilden einer Sprache auf Teile der Prädikatenlogik. Eine solche Sprache lässt sich dann als eine alternative Art und Weise betrachten, um eine Domäne mittels (Teilen der) Prädikatenlogik zu modellieren [Rus10]. Andererseits gab es auch Ansätze wie F-logic [Kif89], welche die Aspekte intuitiver Modellierung und formaler Semantik explizit verbinden. Dieses Vorgehen, eine intuitive konzeptuelle Modellierung mit formaler Semantik und Inferenzmöglichkeit zu

kombinieren, fand seine konsequente Fortsetzung schließlich in den auf Beschreibungsllogiken basierenden Modellierungssprachen des Semantic Web (vgl. Abschnitt 2.2.3).

2.2.3 Semantische Wissensrepräsentation und Ontologien

Die Darstellung der Bedeutung für Domänen-Entitäten ist ein wichtiger Aspekt der Weltmodellierung für kognitive Systeme. Daher wird nachfolgend kurz auf das Thema Semantik in der Wissensrepräsentation eingegangen. Ein wichtiges Werkzeug für semantische Modelle stellen dabei Ontologien dar. Auch auf diese wird in diesem Abschnitt detaillierter eingegangen, z. B. in Bezug auf ihre Erstellung.

Semantik in der Wissensrepräsentation

Der Begriff Semantik kann unterschiedlich verstanden werden, je nachdem, in welcher Wissensdisziplin er gebraucht wird [Kuw11]. Allgemein wird unter Semantik die Lehre der inhaltlichen Bedeutung von sprachlichen Zeichen verstanden [Cla01, Dud96]. Im Bereich der Linguistik bezieht Semantik sich z. B. auf die Bedeutung von natürlichen Sprachen und deren Zeichen wie Wörter oder Sätze. Wird der Zeichenbegriff allgemeiner verstanden, so gehört er zum Bereich der Semiotik, der allgemeinen Lehre der Zeichen [Cha01]. Die Semiotik beschäftigt sich mit der Frage, wie Zeichen allgemein Bedeutung erhalten [Stu86].

Ein grundlegendes Konzept ist dabei die triadische Relation eines Zeichens nach Peirce [Pei58]: um sich auf ein Objekt der realen Welt zu beziehen, wird ein Zeichen verwendet. Dieses als Symbol bezeichnete Zeichen vermittelt bei einem Empfänger eine Idee, d. h. eine gewisse, nicht notwendigerweise korrekte oder präzise Vorstellung über das bezeichnete Objekt. Objekt, Symbol und Vorstellung stehen somit in einer trinären Beziehung zueinander (vgl. auch das sog. semiotische Dreieck). Wichtig ist dabei anzumerken, dass die durch ein Symbol vermittelte Vorstellung nicht notwendigerweise

das gemeinte Objekt betreffen muss. Nach Morris [Mor70] bezieht sich in der Semiotik der Begriff der Semantik nun auf die (binäre) Beziehung zwischen Symbol und Objekt innerhalb der triadischen Relation eines Zeichens. Dies kann für die Domänenmodellierung dabei so interpretiert werden, dass die Bedeutung von verwendeten Symbolen in einem Domänenmodell (z. B. Klassen) möglichst eindeutig das gemeinte (modellierte) Objekt beschreiben soll.

In Informatik und Mathematik betrifft Semantik häufig die Bedeutung der Konstrukte einer formalen Sprache [Cla01], z. B. von Logiken oder Programmiersprachen. Wird diese Bedeutung dabei formal beschrieben (wiederum z. B. mittels Logik), so spricht man von formaler Semantik. Für Programmiersprachen steht die Bedeutung der informationsverarbeitenden Sprachkonstrukte im Vordergrund. Diese kann operational bestimmt sein, also z. B. durch einen Interpreter der betrachteten Sprache, oder auch axiomatisch festgelegt werden durch die Angabe von Vor- und Nachbedingungen für die Operationen der Sprache (z. B. mittels Prädikaten). Für die Domänenmodellierung kann die Angabe von Vor- und Nachbedingungen z. B. relevant sein, um die möglichen Aktionen eines kognitiven Systems in ihrer Bedeutung für die (Veränderung der) Umgebung semantisch modellieren zu können. Auch die Funktionen von Geräten, mit welchen ein kognitives System in Erfüllung seiner Aufgaben interagiert, können derart beschrieben werden. In Bezug auf die konzeptuelle Modellierung in der Informatik bedeutet die semiotische Interpretation von Semantik auch hier, dass die intendierte Bedeutung der modellierten Konzepte möglichst klar beschrieben sein soll. Dies kann einerseits durch eine natürlichsprachliche Annotation von Konzepten (Entitäten, Relationen etc.) erfolgen. Hierbei wird das durch das Konzept repräsentierte Objekt der realen Welt allerdings nur für Menschen beschrieben, jedoch nicht in interpretierbarer Form für eine Maschine. Andererseits kann die Bedeutung eines Konzepts durch seine Beziehungen zu anderen Konzepten spezifiziert werden. Semantik entsteht bei diesem Vorgehen durch die Vernetzung von Informationen – und kann in maschineninterpretierbarer Form repräsentiert werden. In diesem Sinne sind z. B. ER-Modelle semantische Domänenmodelle. Die sich ergebenden Modelle stellen dabei semantische Netze dar.

Semantische Wissensmodelle

Eine Basis für semantische Domänenmodelle können sog. kontrollierte Vokabulare sein. Diese Vokabulare stellen eine sorgfältig erstellte Liste von Begriffen dar, in welcher die Begriffe eindeutig definiert und bezeichnet werden [ANS10]. Alternative Bezeichnungen können dabei als Synonyme markiert werden. Homonyme (gleichlautende Bezeichnungen mit jedoch unterschiedlichen Bedeutungen) müssen dabei unterschieden werden. Kontrollierte Vokabulare können als Glossare, Taxonomie oder Thesauri ausgeprägt sein, mit Glossaren als einfachster Form. Taxonomien fügen gegenüber Glossaren zusätzlich hierarchische Eltern-Kind-Beziehungen („is-a“-Beziehungen) zwischen den definierten Begriffen hinzu [ANS10]. Thesauri erlauben weiterhin die explizite Hinzunahme von Synonym- und Ähnlichkeitsrelationen oder ggf. weiterer, standardisierter Relationen [ANS10].

Ontologien

Eine noch stärkere Vernetzung, und im obigen Sinne eine erhöhte Semantik für das repräsentierte Wissen, kann durch Ontologien als Modelle zur Wissensrepräsentation erreicht werden. Der Begriff Ontologie bezeichnet dabei einerseits eine Art von Domänenmodell, andererseits beschreibt er die einem solchen Modell zugrunde liegende philosophische Disziplin. Die formale Ontologie als philosophische Disziplin ist die Lehre des Seienden [Völ09]. Sie versucht, das Seiende begrifflich zu bestimmen [Bro00] und mittels Kategorisierung eine Systematik der grundlegenden Typen von Entitäten und der Beziehungen zwischen diesen zu bestimmen [Brä03].

Demgegenüber steht die Ontologie als ein konkretes Wissensartefakt der Domänenmodellierung. Eine Ontologie stellt dabei nach Gruber [Gru93] die formale Repräsentation der Konzeptualisierung einer betrachteten Domäne dar, genauer gesagt deren explizite Spezifikation. Ontologien als Domänenmodelle sollen dabei maschineninterpretierbar sein und ein gemeinsames Verständnis der Domäne (von beteiligten Interessensgruppen) reflektieren

[Völ09]. Der Begriff der Ontologie wird im allgemeinem Sprachgebrauch allerdings nicht immer einheitlich verwendet, was die Formalität und Ausdrucksstärke der damit bezeichneten Domänenmodelle betrifft [Völ09].

Im Kern umfasst eine Ontologie als formales Wissensmodell eine Menge von Begriffen [Stu19b]. Diese stellen das Ergebnis einer Konzeptualisierung der betrachteten Domäne dar und werden als Konzepte modelliert. Die Konzepte werden hierbei mittels Attributen beschrieben und sind in einer Taxonomie über „is-a“-Beziehungen hierarchisch angeordnet. Weiterhin ist eine Menge von Relationen gegeben, die die weiteren Beziehungen zwischen den Konzepten (bzw. zwischen Instanzen dieser Konzepte) beschreiben. Auch diese können hierarchisch organisiert sein. Die Begriffe, die zur Bezeichnung der Konzepte und Relationen verwendet werden, sollten ein kontrolliertes Vokabular darstellen und können z. B. in einem Glossar (oft auch als Lexikon bezeichnet) beschrieben werden. Ausdrucksstarke Ontologien beinhalten darüber hinaus formale Axiome. Diese Axiome beschreiben Einschränkungen an die definierten Konzepte und Relationen, z. B. notwendige Relationen für Konzepte, Kardinalitätseinschränkungen an Relationen, Wertebereiche oder sogar feste Werte für Attribute. Mit der Anzahl solcher Axiome steigt, betrachtet im Sinne einer Vernetzung von Information, auch die in einer Ontologie repräsentierte Semantik. Weiterhin können Regeln, formal beschrieben, ein Teil der Ontologie sein und z. B. Herleitungswissen beschreiben. Neben Wissen über die relevanten Klassen von Entitäten einer Domäne und deren Relationen kann in einer Ontologie auch Vorwissen und aktuelle Informationen über konkrete Entitäten repräsentiert werden, als Instanzen der modellierten Konzepte. Eine Ontologie stellt in diesem Fall eine Wissensbasis dar.

Zur praktischen Darstellung eines Domänenmodells durch eine Ontologie ist es sinnvoll, die Ontologie modular in Schichten unterschiedlicher Abstraktionsebenen aufzubauen [Gua98]. Dieses Vorgehen erhöht ebenfalls die Möglichkeit zur Wiederverwendung der erstellten Ontologien [Sch06]. In der Literatur werden unterschiedliche Ebenen genannt, darunter:

- Top-Level Ontologien, welche sehr allgemeine Konzepte unabhängig von einer Domäne oder Anwendung beschreiben [Stu19b, Gua98],

- Kern-Ontologien (bzw. generische Ontologien [Stu19b]), welche aufbauend auf den Festlegungen einer Top-Level Ontologie domänenübergreifend wiederverwendbare Konzepte definieren bzw. Konzepte der Top-Level Ontologie präzisieren – sie stellen ihrerseits die Grundlage für domänenspezifische Ontologien dar [Sch06],
- Domänen-Ontologien, welche domänenspezifische Konzepte beschreiben, aufbauend auf Kern- oder Top-Level Ontologien [Gua98] sowie
- Anwendungs-Ontologien, welche schließlich die spezifischen Konzepte für den Anwendungszweck des Wissensmodells enthalten.

Ontologien dienen auch dazu, Interoperabilität zwischen Akteuren, seien dies Menschen oder Systeme, im Sinne eines gemeinsamen semantischen Verständnisses herzustellen. Neben einer Wiederverwendung modellierten Wissens in anderen Bereichen und Anwendungen ermöglicht es der schichtenweise Aufbau einer Ontologie auch, die Wissensmodelle der tieferen Schichten nach gemeinsamen Prinzipien und Kriterien aufzubauen. Somit können auch die diese Wissensmodelle nutzenden Systeme interoperabler gestaltet werden. So beschreiben Top-Level Ontologien z.B. eine grundlegende Strukturierung von zu repräsentierendem Wissen in prinzipielle Kategorien (wie z.B. die Unterscheidung von Abstraktem gegenüber Konkretem oder von zeitlich Existierendem gegenüber räumlich Existierendem etc.). Dabei kann auch bereits ein grundlegender kognitiver Bias [Mas03] festgelegt werden, im Sinne einer bestimmten philosophischen Sichtweise oder Interpretation der (zu modellierenden) Welt. Dies kann beispielsweise die Art und Weise der Modellierung von Zeit, die Modellierung von Modalität oder das Abstraktionsniveau, auf welchem die Welt betrachtet wird, betreffen. Durch Kern-Ontologien können weitere, spezifischere Annahmen über die Welt beschrieben werden, welche zwar nicht als prinzipiell allgemeingültig gelten können, aber im Rahmen eines verfolgten Ansatzes für alle zu modellierenden Domänen gelten sollen, wie z.B. eine probabilistische Darstellung von Attributwerten.

Ontologien als formale Wissensmodelle ermöglichen es, ein konzeptuelles Modell einer Domäne zu repräsentieren. Weiterhin verfügen viele Modellierungssprachen für Ontologien über eine formale Semantik und ermöglichen mittels ihrer formalen Axiome und Regeln das Schlussfolgern durch deduktive Inferenz. Ontologien vereinigen somit die Vorteile unterschiedlicher Vorgehen zur Domänenmodellierung in einem einheitlichen Ansatz.

Beschreibungslogiken

Wie die Konzeptualisierung einer Domäne konkret als Ontologie repräsentiert wird, hängt von der verwendeten Ontologiesprache ab. Auch die Möglichkeit zur Inferenz im Domänenmodell sowie deren Berechnungskomplexität¹ werden von der Ontologiesprache bestimmt. Eine Ontologiesprache sollte dabei idealerweise ausdrucksmächtig genug sein, um die Eigenheiten einer Domäne möglichst spezifisch und formal repräsentieren zu können. Allerdings steigt i. A. mit der Ausdrucksmächtigkeit der Ontologiesprache auch die Berechnungskomplexität der Inferenz (bis hin zur Unentscheidbarkeit in der Prädikatenlogik). Für Anwendungen muss daher ein angemessener Kompromiss gefunden werden.

Eine relevante Art von formalen Ontologiesprachen stellen die sog. Beschreibungslogiken dar. Die nachfolgende Darstellung von Beschreibungslogiken basiert, wenn nicht anders angegeben, auf Informationen aus [Baa03]. Beschreibungslogiken sind eine Familie von Repräsentationssprachen, welche auf Teilmengen der Prädikatenlogik basieren [Völ09]. Sie wurden entworfen, um die formale Beschreibung einer Domäne zu vereinfachen und stellen eine Weiterentwicklung von Frames und semantischen Netzen dar [Rus10], vor allem im Hinblick auf ihre formale Semantik.

Als Familie von Repräsentationssprachen ermöglichen Beschreibungslogiken einen Kompromiss zwischen Ausdrucksmächtigkeit einer konkreten

¹ Der Begriff Berechnungskomplexität bezieht sich auf die Komplexität eines Problem im Sinne der Komplexitätstheorie – und wird hier, zur besseren Unterscheidbarkeit, mit dem Bestimmungswort „Berechnung“ verwendet.

Sprache und der Berechnungskomplexität ihrer Inferenz¹. Entscheidbarkeit wird hierbei als Anforderung an eine praxisrelevante Beschreibungssprache vorausgesetzt. Eine ausdrucksmächtigere Beschreibungssprache ermöglicht die detailliertere Modellierung einer Anwendungsdomäne und ermöglicht somit eine erhöhte Semantik der Modelle, geht aber i. A. zugleich mit einer gesteigerten Worst-Case-Berechnungskomplexität einher.

Beschreibungslogiken ermöglichen ein Zuschneiden der Beschreibungssprache an die Anforderungen der Domäne und der intendierten Anwendung. Ausgehend von atomaren Konzepten definieren sie zu diesem Zweck sog. Konstruktoren, die es ermöglichen, atomare Konzepte zu komplexen Konzepten zusammensetzen. Je nachdem, welche Konstruktoren in einer Beschreibungssprache zulässig sind, ergeben sich unterschiedlich ausdrucksmächtige Sprachen. Konzepte werden in Beschreibungslogiken dabei nach modelltheoretischer Semantik als Mengen von Individuen interpretiert. Die grundlegenden Konstruktoren beinhalten den Schnitt von Konzepten, ihre Vereinigung sowie die Negation (Komplement) eines (atomaren oder komplexen) Konzepts. Weiterhin dienen auch Einschränkungen an die möglichen Relationen eines Konzepts als Konstruktoren. Hierbei kann u. a. eine Mindest- oder Höchstzahl von Relationen eines Typs gefordert werden oder auch festgelegt werden, dass alle von einem Konzept ausgehenden Relationen eines bestimmten Typs nur zu einem bestimmten anderen Konzept bestehen dürfen.

Wird eine Beschreibungslogik zur Domänenmodellierung verwendet, so bestimmt die Menge der durch den Anwender definierten atomaren und komplexen Konzepte die Terminologie, mittels derer die Gegebenheiten der Anwendungsdomäne repräsentiert werden können. Auf Basis dieser Konzepte können, unter Verwendung weiterer Operatoren für Konzepte wie der Gleichheit und der Teilmengen-Beziehung, Formeln definiert werden. Diese Formeln können z. B. eine „is-a“-Hierarchie der Konzepte beschreiben sowie benannte Konzepte definieren, wobei ein atomares Konzept (als Name)

¹ Die wichtigsten Inferenzaufgaben betreffen hier die Erfüllbarkeit eines Modells sowie die Subsumtion, d. h. das Enthaltensein eines Konzepts in einem anderen [Don03].

einer komplexen Konzeptbeschreibung gleichgesetzt wird. Die Menge dieser axiomatischen Formeln wird als TBox bezeichnet und beschreibt formal das Vokabular der Anwendungsdomäne als ein konzeptuelles Modell. Wissen über konkrete Entitäten der Domäne wird in der sog. ABox in Form von Instanzen der Konzepte der TBox repräsentiert. TBox und ABox bilden zusammen eine Wissensbasis für die Anwendungsdomäne.

Je nach zugelassenen Konzept-Konstruktoren kann die Berechnungskomplexität von Inferenzaufgaben in der sich ergebenden Beschreibungssprache in eine der Komplexitätsklassen von P bis NEXPTIME fallen [Don03]. Die Hinzunahme von Axiomen in der TBox, vor allem von Teilmengen-Beziehung („is-a“-Hierarchie), kann die Komplexität gegenüber der Inferenz auf einer reinen Menge von Konzepten deutlich erhöhen. Trotz einer grundsätzlich hohen Berechnungskomplexität ist die Inferenz in einer Beschreibungslogik trotzdem häufig praktisch nutzbar und nützlich. Dies liegt darin begründet, dass in der Praxis der mittlere Zeitaufwand für „vernünftig“ große Problem häufig weit unter der theoretischen Berechnungskomplexität liegt [Don03]. Unterstützt wird dies durch die Tatsache, dass die Forschung an entsprechenden Inferenzalgorithmen lange Zeit darauf abzielte, für immer ausdrucksmächtigere Beschreibungslogiken Verfahren zu finden, die durch Optimierung in der Praxis in ihrer Laufzeit größtenteils beherrschbar bleiben [Baa05].

Web Ontology Language

Mit der zunehmenden Verbreitung des Internets wurde auch das World Wide Web (WWW) immer mehr zu einer ubiquitär verfügbaren Quelle von Informationen. Vor diesem Hintergrund wurde von Tim Berners-Lee die Idee eines Semantic Web [Ber01] als Erweiterung des WWW geäußert. Dabei soll das im WWW enthaltene Wissen strukturiert werden, indem die auf Webseiten dargestellten Informationen um eine Beschreibung ihrer Bedeutung ergänzt werden [Kuc04]. Ziel ist, diese Informationen auch für Maschinen durchsuchbar, lesbar und automatisiert verarbeitbar zu machen, so dass

komplexere Aufgabenstellungen z. B. von intelligenten Softwareagenten autonom bearbeitet werden können. Um dies zu erreichen, werden sowohl eine gemeinsame Begriffsbildung als auch Sprachen zur Auszeichnung der Bedeutung von Informationen benötigt [Stu19a]. Weiterhin müssen diese Auszeichnungen automatisiert verarbeitet und kombiniert werden können.

Als Werkzeuge für diese Zwecke sind Ontologien und Beschreibungslogiken geeignet [Hor03]. Im Bereich des Semantic Web bauen Beschreibungssprachen hierarchisch auf anderen Technologien und Standards des WWW auf (sog. Semantic Web Stack). Zu diesen zählen URIs¹ zur eindeutigen Identifizierung von Begriffen sowie XML² bzw. RDF³ als Auszeichnungssprachen zur Beschreibung von Beziehungen zwischen Begriffen (auf Basis sog. Subjekt-Prädikat-Objekt Tripel). Um auf dieser Basis die notwendige Ausdrucksmächtigkeit einer Beschreibungssprache für das Semantic Web zu erreichen, wurde schließlich die Web Ontology Language OWL als formale Ontologiesprache entwickelt und vom W3C⁴ als offizieller Standard etabliert [Hor03]. OWL setzt dabei auf Beschreibungslogiken auf. Durch die anhaltende Bedeutung des WWW wurde die Forschung im Bereich des Semantic Web somit zugleich zu einem Treiber der Weiterentwicklung im Bereich von Beschreibungslogiken und Techniken zur effizienten Inferenz in diesen sowie von Werkzeugen zur Erstellung und Verwaltung komplexer ontologischer Domänenmodelle.

OWL ist eine Weiterentwicklung aus Vorgängersprachen [W3C04]. Die Ausdrucksmächtigkeit der Sprachen sollte dabei die Bedeutung von Informationen im Bereich des WWW repräsentieren können. In das Design der Sprachen floss weiterhin auch der Anspruch ein, sowohl die üblichen Sprachelemente von objektorientierten bzw. frame-basierten Sprachen bereitstellen zu können als auch mittels formaler Semantik automatisiertes Schlussfolgern zu ermöglichen [Hor03]. Als Ergebnis dieser Bemühungen vereinigt

¹ Uniform Resource Identifier, vgl. RFC 3986 (<https://tools.ietf.org/html/rfc3986>)

² Extensible Markup Language, W3C Recommendation (<https://www.w3.org/TR/xml/>)

³ Resource Description Framework, W3C Recommendation (<https://www.w3.org/TR/rdf11-concepts/>)

⁴ WWW Consortium, das für das WWW zuständige Standardisierungsgremium

OWL nun viele der bereits genannten Aspekte, die für eine sowohl intuitive als auch formale Domänenmodellierung wichtig sind. OWL als konsolidierter, umfassender Ansatz stellt dabei den Stand der Technik der logikbasierten Domänenmodellierung dar [Stu19b].

Der Standard des W3C zur OWL ist bereits in zweiter Version verfügbar [W3C12]. OWL definiert darin eine Familie von Ontologiesprachen: OWL Full, OWL DL und OWL Lite für OWL 1, sowie OWL 2 Full/DL und OWL 2 EL, OWL 2 QL und OWL 2 RL. Diese Sprachen stehen dabei teilweise in hierarchischer Enthaltenseins-Beziehungen zueinander, in dem Sinne, dass eine Sprache eine syntaktische Teilmenge einer anderen ist. Die Sprachen dieser Familie stellen jeweils einen Kompromiss zwischen Ausdrucksmächtigkeit und Berechnungskomplexität dar. Manche der Sprachen lassen sich als Beschreibungslogiken interpretieren bzw. basieren auf solchen, z. B. OWL DL, OWL 2 DL (der Zusatz „DL“ steht für Description Logic) und OWL 2 EL (der Zusatz „EL“ bezieht sich auf die Beschreibungslogik EL++ [Baa05]). Inferenz in OWL 2 EL ist dabei sogar effektiv berechenbar¹, d. h. in der Komplexitätsklasse P [W3C09]. Trotz Einschränkungen in ihrer Ausdrucksmächtigkeit ist diese Teilsprache wichtig für praktische Anwendungen, z. B. im Bereich der Medizin [Baa05]. OWL 2 DL basiert auf der Beschreibungslogik SROIQ(D), einer Erweiterung der Beschreibungslogik SHOIN(D), auf welcher OWL DL basiert [Völ09, W3C12]. Die Benennung einer Beschreibungslogik erfolgt dabei nach einem Schema, in welchem jeder Buchstabe eine Menge erlaubter Konstruktoren bei der Definition von Konzepten repräsentiert [Baa03]. Die Beschreibungslogik SROIQ erlaubt somit u. a. folgende Konstruktoren:

- Vereinigung, Schnitt und Komplementbildung für Konzepte,
- Enumeration von Individuen,
- Bedingungen an Beziehungen zu anderen Konzepten, auch gebunden an den Typ der Beziehung, wie
 - mindestens eine Beziehung eines Typs (auch zu einem vorgegebenen anderen Konzept),

¹ Übersetzung von „computationally tractable“

- genaue Anzahl von Beziehungen eines Typs (auch zu einem vorgegebenen anderen Konzept),
 - nur Beziehungen eines Typs zu einem vorgegebenen anderen Konzept
- sowie eine Hierarchie von Beziehungen und die Definition von transitiven, reflexiven oder inversen Beziehungen.

Der Zusatz „(D)“ beschreibt dabei, dass die Verwendung konkreter Datentypen erlaubt ist. Beide OWL DL Beschreibungslogiken sind entscheidbar, die Worst-Case-Komplexität der Inferenz liegt allerdings in der Komplexitätsklasse NEXPTIME (bzw. 2NEXPTIME) [W3C09]. Trotz dieser in der Theorie hohen Berechnungskomplexität kann in der Praxis oftmals eine akzeptable Laufzeit für Inferenzaufgaben erreicht werden, da Inferenzwerkzeuge (sog. Reasoner) entsprechend darauf optimiert sind [Baa05, Don03]. Für OWL 2 stehen weiterhin Werkzeuge zur Verfügung, mit deren Hilfe Ontologien entwickelt, validiert und eingesetzt werden können. Für die graphische Entwicklung von Ontologien steht beispielsweise das Werkzeug Protégé¹ [Mus15] frei zur Verfügung, welches eine direkte Einbindung von Inferenzwerkzeugen wie Hermit [Gli10] und Pellet [Sir07] ermöglicht, für das Ziehen von Schlussfolgerungen sowie zur Konsistenzprüfung.

Ausdrucksstärke und Bedeutung in formalen Modellen

Trotz der Ausdrucksmächtigkeit formaler Ontologiesprachen muss man sich darüber im Klaren sein, dass das semantische Modell, das sich im Sinne einer Bedeutung der modellierten Konzepte ergibt, für ein kognitives System rein aus der Vernetzung von symbolischen Bezeichnungen besteht. Die Vorstellungen (im Sinne der triadischen Relation der Semiotik), die wir Menschen zusätzlich mit diesen Bezeichnungen verbinden, erschließen sich dem kognitiven System nicht (vgl. z. B. [Völ09]). Dazu wäre es notwendig, dass das kognitive System zumindest einer Teilmenge der symbolischen Bezeichnungen eine dem Wissensmodell externe Bedeutung zuordnen kann – z. B.

¹ Verfügbar unter: <https://protege.stanford.edu/>

in Form von sensorischen Eindrücken oder Erfahrungswerten (vgl. das sog. Symbol Grounding Problem). Die Ausdrucksstärke eines ontologischen Modells kann nach Völker [Völ09] formal darüber beschrieben werden, wie viele mögliche Welten ein Modell als logische Interpretationen durch seine Axiomatisierung ausschließt, bezogen auf die zu modellieren beabsichtigten Welten. Je mehr unbeabsichtigte Welten ausgeschlossen werden, desto ausdrucksstärker ist die erstellte Ontologie.

Ontologie-Entwurf und Prinzipien der formalen Ontologie

Ontologien als Wissensmodelle stellen Ingenieursartefakte dar. Um qualitativ hochwertige Ontologien entwerfen zu können, ist daher ein strukturiertes Vorgehen erforderlich. Für den Ontologie-Entwurf finden sich in der Literatur zahlreiche Vorgehensmodelle und Empfehlungen, darunter die von Damm [Dam03] und Noy [Noy01]. Stollberg [Sto02] gibt weiterhin einen Überblick über einige dieser Vorgehensmodelle. Gemeinsam ist den Ansätzen dabei eine Aufteilung in Phasen. An eine initiale Analyse- und Spezifikationsphase schließt sich eine Konzeptualisierungsphase an, gefolgt von einer Definitions- und Formalisierungsphase und schließlich abgeschlossen durch eine Evaluationsphase [Sto02, Dam03]. In der Analysephase werden u. a. Domäne, gewünschter Einsatzzweck und Nutzer der Ontologie ermittelt und festgestellt. Weiterhin können sog. Kompetenzfragen [Grü95] spezifiziert werden. Dies sind Fragestellungen, auf welche das zu entwickelnde Wissensmodell Antworten bereitstellen können soll. Kompetenzfragen begleiten den Entwicklungsprozess, z. B. zur Ableitung von Entwurfsentscheidung. Sie dienen dabei auch zur Auswahl der zu repräsentierenden Entitäten und Beziehungen. Die Konzeptualisierung beschäftigt sich mit der Herausbildung der relevanten Konzepte für die zu modellierende Domäne. Dabei werden ausgehend von relevanten Begriffen der Domäne Klassen gebildet, diese taxonomisch angeordnet und mittels Attributen beschrieben. In der Definitionssphase wird die erstellte Konzeptualisierung formal repräsentiert. Dabei werden auch bereits existierende Ontologien eingebunden,

wie z. B. eine Top-Level Ontologie. In der Evaluationsphase wird die erstellte Ontologie in Bezug auf Kriterien wie Vollständigkeit und logische Konsistenz qualitätsgeprüft. Weiterhin wird geprüft, ob die Ontologie in der Lage ist, die spezifizierten Kompetenzfragen zu beantworten. Eine Qualitätssicherung kann insgesamt auch phasenübergreifend während des gesamten Entwicklungsprozesses erfolgen, ebenso wie die Dokumentation von Entwurfsprinzipien und Umsetzungsentscheidungen.

Qualitätskriterien Allgemeine Kriterien, die für eine Entwicklung von qualitativ hochwertigen Ontologien beachtet werden sollten, werden von Gruber [Gru95] genannt. Darunter sind:

- Klarheit bezüglich der definierten Konzepte, indem diese so weit wie möglich durch Axiome formal beschrieben sowie natürlichsprachlich dokumentiert werden,
- Kohärenz und Konsistenz, dies betrifft einerseits die Kohärenz zwischen formaler und natürlichsprachlicher Beschreibung, andererseits die Widerspruchsfreiheit der formalen Axiome,
- Erweiterbarkeit, um eine Ontologie möglichst abwärtskompatibel erweitern zu können,
- minimale Abhängigkeiten von Repräsentations- und Implementierungsdetails, um eine Ontologie flexibel mittels unterschiedlicher Formalismen umsetzen und anwenden zu können,
- minimale, nur notwendige ontologische Festlegungen, um innerhalb des von der Ontologie intendierten Rahmens möglichst viele Anwendungsfälle unterstützen zu können.

OntoClean Ein konkretes Vorgehensmodell mit spezifischer Zielsetzung ist durch die OntoClean Methodik von Guarino und Welty [Gua02] gegeben. OntoClean setzt auf Prinzipien der formalen Ontologie (als philosophischer Disziplin) auf und legt seinen Schwerpunkt auf die diesbezüglich korrekte Erstellung taxonomischer „is-a“-Beziehungen. Hierfür werden die Konzepte einer Ontologie zunächst mit Meta-Eigenschaften annotiert, durch welche die Konzepte nach Aspekten der formalen Ontologie wie Essenz, Einheit oder Abhängigkeit charakterisiert werden. Auf Basis dieser Annotationen

definiert OntoClean Regeln, mit deren Hilfe unzulässige taxonomische Beziehungen in einer Ontologie identifiziert werden können, was zur Vermeidung formaler Modellierungsfehler und deren Konsequenzen beiträgt.

2.2.4 Repräsentation probabilistischer Informationen

Bisher wurden Ansätze zur Repräsentation von sicherem Vorwissen betrachtet. Die objektorientierte Weltmodellierung muss allerdings auch in der Lage sein, unsichere Informationen als Vorwissen in einem Wissensmodell darstellen zu können (vgl. 2.2.1). Unsicherheit in Wissen kann unterschiedliche Ursache haben, darunter die nur unvollständige Bekanntheit von Wissen oder die (in der Praxis) nur unvollständig mögliche Erfassung und Repräsentation bekannten Wissens [Rus10]. Auch im Bezug auf die Messung von Eigenschaften oder Größen relevanter Entitäten einer Domäne können die gewünschten Informationen unter Umständen nur ungenau erfasst oder nur indirekt beobachtet werden [Sch11].

Unsicherheit in Informationen und Wissen kann ihrer Art nach unterschiedlich behandelt werden. Bei der Domänenmodellierung kann es z. B. vorkommen, dass sich manche Begriffe nur unscharf definieren lassen – beispielsweise, weil bereits die natürlichsprachliche Bedeutung eines Begriffs nur vage angegeben werden kann. Soll ein solcher Begriff formal modelliert werden, z. B. als ein Prädikat der Prädikatenlogik oder ein Konzept der Beschreibungslogik, überträgt sich die Problematik: die Menge der enthaltenen Individuen kann nicht scharf begrenzt werden. Unsicherheit in Form solcher vager Beschreibungen kann über die unscharfen Mengen der Fuzzy Logik [Zad65] behandelt werden. Anstelle der binären Zugehörigkeit eines Individuums zu einer Menge erlauben diese eine graduelle Zugehörigkeit, ermöglicht durch die Verwendung einer sog. Zugehörigkeitsfunktion mit reellen Werten auf dem Intervall $[0,1]$. Die Fuzzy Logik beschreibt dann, wie aufbauend auf solchen unscharfen Beschreibungen Schlussfolgerungen gezogen werden können [Rus10].

Eine weitere Facette von Unsicherheit wird durch Unwissen dargestellt. Eine explizite Unterscheidung von Unwissen über einen Sachverhalt und nur unsicherer Information über diesen wird in der Evidenztheorie nach Dempster-Shafer betrachtet [Dem68, Sha76]. Dabei wird insbesondere ermöglicht, das Unwissen über einen Sachverhalt explizit zu quantifizieren. In der Wahrscheinlichkeitstheorie wird, falls für das Gelten einer Aussage A eine Wahrscheinlichkeit $p(A)$ bekannt ist, implizit die Wahrscheinlichkeit $1 - p(A)$ für das Nichtgelten der Aussage angenommen. In der Dempster-Shafer Evidenztheorie bestimmt dahingegen eine quantifizierte Evidenz $k(A)$ für das Gelten einer Aussage nur den Glauben (im Sinne eines Grades des Dafürhaltens) an das Gelten der Aussage. Ein irgendwie geartetes Dafürhalten über das Nichtgelten der Aussage wird hierdurch nicht impliziert. Der Glaube, dass die Aussage nicht gilt, bleibt also durch die Evidenz für das Gelten der Aussage unverändert – genauer gesagt sogar solange gleich 0, bis eine explizite Evidenz für das Nichtgelten vorliegt. Wenn eine solche Evidenz tatsächlich vorliegt, mit Konfidenz $k(\bar{A})$, so wird die Plausibilität des Geltens von A explizit reduziert, und zwar auf den Wert $1 - k(\bar{A})$. Der Glaube an das Gelten der Aussage A wird dann, entsprechend der explizit vorliegenden Evidenzen, über das Intervall $[k(A), 1 - k(\bar{A})]$ quantitativ beschrieben. In Bezug auf die Semantik impliziter und expliziter Feststellungen zu Sachverhalten ähnelt die Evidenztheorie in ihrem Ansatz somit dem Vorgehen der sog. Open-World-Semantik von Beschreibungslogiken. Hierbei wird angenommen, dass Aussagen, zu denen bisher keine Informationen in einer Wissensbasis vorliegen, als unbekannt gelten – und nicht automatisch als falsch gelten, wie dies unter der gegensätzlichen Closed-World-Semantik von z. B. Datenbanksystemen interpretiert werden würde [Baa03].

Einen systematischen Ansatz zur einheitlichen Behandlung unsicherer Informationen, mit weiter Verbreitung [Noa10] und langer wissenschaftlicher Tradition [Rus10], stellt schließlich die Wahrscheinlichkeitstheorie dar. In den bisherigen Arbeiten zum objektorientierten Weltmodell werden unsichere Informationen aus Beobachtungen ebenfalls auf Basis der Wahrscheinlichkeitstheorie behandelt [Hei10]. Unsichere Eigenschaften beobachteter Domänen-Entitäten werden dabei über Wahrscheinlichkeitsverteilung im

Sinne eines Grades des Dafürhaltens beschrieben. Eine derartige Repräsentation unsicheren Wissens ist somit auch eine wichtige Anforderung an die Wissensmodellierung im objektorientierten Weltmodell (vgl. 2.2.1). Im Folgenden wird daher auf die probabilistische Repräsentation unsicherer Informationen in der Wahrscheinlichkeitstheorie eingegangen.

Probabilistische Repräsentation

Im Vergleich zur formalen Darstellung im Bereich der Logik werden probabilistische Informationen traditionell informaler und nahe an der mathematischen Notation repräsentiert [Rus10]. Unsicherheit in Bezug auf einen einzelnen Aspekt (beispielsweise den Wert einer Eigenschaft einer Domänen-Entität) wird in probabilistischen Domänenmodellen oft als Zufallsvariable modelliert und über Wahrscheinlichkeitsverteilungen bzw. Dichtefunktionen dargestellt. Die Verteilungen diskreter Zufallsvariablen können dabei in tabellarischer Form repräsentiert werden. Die Dichtefunktionen stetiger Zufallsvariablen sind als reellwertige Funktionen i. A. schwieriger zu repräsentieren. Allerdings werden in der Praxis häufig parametrische Verteilungsannahmen für stetige Zufallsvariablen getroffen, die es ermöglichen Standardfamilien von Wahrscheinlichkeitsverteilungen über eine endliche Anzahl an Parametern kompakt darzustellen.

Neben der probabilistischen Modellierung einzelner Eigenschaften durch skalare Zufallsvariablen ist auch die Modellierung von probabilistischen Zusammenhängen zwischen Entitäten (bzw. Konzepten) von Bedeutung. Diese Zusammenhänge werden probabilistisch über die gemeinsame Wahrscheinlichkeitsverteilung der beteiligten Zufallsvariablen modelliert. Es lassen sich verschiedene Arten von Zusammenhängen unterscheiden, darunter stationäre und dynamische Zusammenhänge. Stationäre (statische) Zusammenhänge können beispielsweise kausale Beziehungen (Ursache und Wirkung) zwischen Entitäten modellieren. Sie ermöglichen eine probabilistische Repräsentation von Zusammenhängen, die in Logik mittels Regeln dargestellt werden. Neben stationären Zusammenhängen sind auch

dynamische, zeitbezogene Zusammenhänge relevant. Sie stehen in enger Beziehung zur Repräsentation des Zustandes eines dynamischen Systems.

Für die objektorientierte Weltmodellierung sind dynamische Zusammenhänge beispielsweise von Interesse, wenn der Zustand der relevanten Umgebung eines kognitiven Systems schritthaltend modelliert werden soll. Die Wissensrepräsentation muss daher in der Lage sein, derartige Zusammenhänge im Vorwissen darstellen zu können. Zustände werden dabei oftmals als Zufallsvektoren modelliert, d. h. als mehrere, zu einem Vektor zusammengefasste Zufallsvariablen. Der dynamische Zusammenhang besteht oft zwischen verschiedenen Ausprägungen des den Zustand beschreibenden Zufallsvektors zu unterschiedlichen (z. B. diskreten) Zeitpunkten. Der Zustand zum aktuellen Zeitpunkt kann probabilistisch von vorhergehenden Zuständen abhängen beziehungsweise, bei Systemen mit Markov-Eigenschaft, z. B. von seinem direkten Vorgängerzustand.

Wenn probabilistische Zusammenhänge vorwiegend dazu genutzt werden, um von einer Zufallsvariablen (bzw. einer Menge) auf andere Zufallsvariablen zu schließen, sind neben der gemeinsamen Verteilung der Zufallsvariablen vor allem bedingte Verteilungen von Interesse. Zum Beispiel beschreibt die Verteilung eines Nachfolgezustandes bedingt auf den Vorgängerzustand die probabilistische Transition des Zustandes über einen Zeitschritt hinweg. Somit ist auch die Repräsentation bedingter Verteilungen von Interesse. Für diskrete Zufallsvektoren können bedingte Verteilungen in Form von Matrizen repräsentiert werden [Sch11]. Für Vektoren stetiger Zufallsvariablen ergibt sich die bedingte Verteilung als eine reellwertige Funktion mit den beteiligten Zufallsvariablen als Variablen. Auch hier kann es möglich sein, parametrisierbare Klassen von Funktionen zu verwenden, z. B. lineare Normalverteilungen (deren Mittelwert linear variiert) [Rus10]. Dies hängt allerdings von den Gegebenheiten des Anwendungsfalls ab.

Stationäre Zusammenhänge, vor allem kausale Beziehungen, sind für die probabilistische Form der deduktiven Inferenz von Interesse. Gegenüber logischen Regeln ermöglichen sie auch unter unvollständigem Wissen (z. B. bezüglich der Prämissen einer Regel) das Ziehen von Schlussfolgerungen.

Kausale Zusammenhänge werden probabilistisch ebenfalls durch die gemeinsame Wahrscheinlichkeitsverteilung der beteiligten Zufallsvariablen repräsentiert. Eine probabilistische Inferenz kann, in Form einer Anfrage, wiederum über eine bedingte Verteilung beschrieben werden: Gesucht wird die Verteilung der interessierenden Zufallsvariablen bedingt auf andere Zufallsvariablen, deren Werte gegeben sind und als Evidenzen dienen.

In der probabilistischen Modellierung dient die gemeinsame Verteilung relevanter Zufallsvariablen als eine Art Wissensbasis [Rus10], die das vorhandene Wissen über die Zufallsvariablen und ihre Zusammenhänge repräsentiert. Eine derartige Repräsentation kann allerdings schnell sehr komplex werden, in zweierlei Hinsicht. Einerseits müssen die Zusammenhänge relevanter Zufallsvariablen für die betrachtete Domäne zunächst einmal ermittelt und anschließend in einer Wissensrepräsentation dargestellt werden. Für große Domänen kann dabei nicht nur der entsprechende Arbeitsaufwand problematisch sein, sondern bereits das bloße Ermitteln der benötigten Informationen. Andererseits steigt der Berechnungsaufwand der Inferenz mit der Größe der Zusammenhänge, d. h. der Anzahl der beteiligten Zufallsvariablen, exponentiell an [Rus10]. Eine Möglichkeit, dieser Komplexität zumindest teilweise Herr zu werden, besteht im Ausnutzen von Unabhängigkeitsannahmen für die beteiligten Zufallsvariablen.

Probabilistisch graphische Modelle Ein solches Ausnutzen von Unabhängigkeitsannahmen wird als Ansatz in probabilistischen graphischen Modellen [Jor04] verfolgt, welche parametrierbare Wahrscheinlichkeitsverteilungen auf Basis von Graphen definieren. Bayes'sche Netze stellen dabei einen Spezialfall graphischer Modelle basierend auf gerichteten Graphen dar [Rus10]. Graphische Modelle ermöglichen es, stochastische Unabhängigkeit zwischen beteiligten Zufallsvariablen auszunutzen, um eine weniger komplexe Repräsentation der gemeinsamen Verteilung zu finden. Dies wird über eine Faktorisierung der gemeinsamen Verteilung erreicht, wobei diese in einzelne Verteilungen über unabhängigen Zufallsvariablen faktoriisiert wird. Bayes'sche Netze ermöglichen eine derartige Faktorisierung sogar unter Verwendung der weniger starken Annahme einer nur bedingten

Unabhängigkeit zwischen (Teilmengen von) Zufallsvariablen. Derartige Gegebenheiten sind in der Praxis wesentlich häufiger anzutreffen. Die Faktorisierung ermöglicht weiterhin eine gesteigerte Effizienz der Inferenz, wodurch das probabilistische Schlussfolgern auch in praktischen Anwendungen skalierbar wird [Rus10]. Aufgrund ihres systematischen Vorgehens bei der Definition von Wahrscheinlichkeitsverteilungen, vor allem in Bezug auf das Explizieren von Abhängigkeitsstrukturen, werden graphische Modelle als ein geeignetes Verfahren für eine allgemeine Bayes'sche Inferenz angesehen [Jor04].

Gegenüber den vorgestellten Ansätzen zur konzeptuellen bzw. semantischen Domänenmodellierung besitzen rein graphische Modelle allerdings einige Nachteile für ihre Anwendbarkeit in großen Domänen. So werden Bayes'sche Netze z. B. als nicht geeignet angesehen, um probabilistische Zusammenhänge in komplexen strukturierten Domänen effizient modellieren zu können [Kol98, How09]. Dies liegt darin begründet, dass die Domänenmodellierung mittels Bayes'schen Netzen auf der Ebene der Aussagenlogik stattfindet [Kol97, Mil06, Rus10]. Zufallsvariablen repräsentieren einzelne, nicht weiter strukturierte Aussagen. Die in einer Domäne vorhandene Struktur kann somit nicht für eine effizientere Modellierung ausgenutzt werden (z. B. durch Klassen zur Abstraktion sich wiederholender Anteile in der Domäne). Auch sind gewisse Annahmen in Bayes'schen Netzen nach ihrer Erstellung fest kodiert, wie beispielsweise die Anzahl betrachteter Entitäten [How09]. Die sich unter diesen Bedingungen für komplexe Domänen ergebenden Modelle sind in ihrer Erstellung, Wartung und Verständlichkeit nur schwer für Menschen handzuhaben. Zugleich sind diese Modelle auch bereits in Bezug auf ihren Berechnungsaufwand für Inferenzaufgaben praktisch oft nicht einsetzbar [How09].

Als Konsequenz aus dieser Erkenntnis wurden Modelle entwickelt, welche die Vorteile der Domänenmodellierung von konzeptuellen oder semantischen Modellierungssprachen mit der Fähigkeit graphischer Modelle zur Behandlung von Unsicherheit verbinden.

Kombinierte Ansätze

Kombinierte logisch-probabilistische Ansätze zur Domänenmodellierung verbinden graphische Modelle mit Methoden der objektorientierten Modellierung (Klassen, Vererbung etc.), der semantischen Modellierung (framebasierte Systeme, OWL) oder direkt mit Prädikatenlogik. Diese Ansätze werden übergreifend unter der Bezeichnung „First-order Probabilistic Languages“ (FOPL) zusammengefasst und zeichnen sich durch die Fähigkeit aus, auch komplexe probabilistische Zusammenhänge kompakt durch objektbezogene Abstraktionen repräsentieren zu können [Mil06].

Eine Übersicht über verschiedene FOPL und ihrer Eigenschaften wird von Milch und Russell [Mil06] gegeben. Die betrachteten FOPL werden nach bestimmten Kriterien taxonomisch strukturiert. Wichtige Kriterien sind dabei, für welche Aspekte der Domäne, auf welche Weise und wie weitgehend ein Ansatz ein Wahrscheinlichkeitsmodell der Domäne repräsentieren kann, und ob es möglich ist, das Wahrscheinlichkeitsmodell über einer unbekanntem bzw. variablen Anzahl von Objekten aufzustellen. Als besonders relevant werden dabei Ansätze betrachtet, welche

- Wahrscheinlichkeitsverteilungen über den möglichen Welten einer (logischen) Wissensbasis beschreiben, und zwar
- strukturiert mittels Faktorisierung in bedingter Verteilung als lokale Modelle, und dabei
- nicht von vornherein auf eine feste Anzahl von repräsentierten Entitäten festlegen sind.

Entsprechende Ansätze werden in dieser Arbeit ebenfalls als relevant zur Wissensrepräsentation für eine objektorientierte Weltmodellierung betrachtet und nachfolgend näher beschrieben.

Objektorientierte Ansätze Einen ersten Schritt in Richtung eines höheren Abstraktionsgrades probabilistischer Modelle gehen Koller und Pfeffer in [Kol97] mit ihren objektorientierten Bayes'schen Netzen (OOBN). Diese ermöglichen es, sich wiederholende Strukturen einer Domäne effizient zu

repräsentieren, indem Entitäten zu Klassen zusammengefasst werden können und für diese Vererbung unterstützt wird. Die Klassen besitzen dabei Attribute, für welche lokale probabilistische Modelle definiert werden können. Mittels dieser sog. Fragmente Bayes'scher Netze werden probabilistische Abhängigkeiten zu Attributen auch anderer Klassen repräsentiert. Auf Grundlage einer Wissensbasis, d. h. einer bekannten Anzahl von Instanzen pro Klasse, können die lokalen Modelle zu einem probabilistischen Gesamtmodell in Form einer gemeinsamen Wahrscheinlichkeitsverteilung der Attribute aller Instanzen zusammengesetzt werden.

Eine Erweiterung von OOBN sind die sog. probabilistisch-relationalen Modelle (PRM) [Kol98]. Diese erweitern die Fähigkeiten von OOBN beispielsweise in Bezug auf die Repräsentation eines probabilistischen Modells mit einer unsicheren Anzahl von Objekten und unsicheren Beziehungen zwischen diesen. Des Weiteren verbinden sie die probabilistische und semantische Modellierung, indem ein framebasierter Ansatz zur Erstellung und Verwaltung der zugrundeliegenden Wissensbasis genutzt wird. Die verwendeten Frames werden dabei um die Möglichkeit erweitert, lokale probabilistische Modelle für die Attribute eines oder mehrerer in Beziehung stehender Frames darzustellen. Möglich ist dies auch für bereits existierende Domänenmodelle, so dass diese nachträglich um probabilistische Modellanteile erweitert werden können. Mit der Fähigkeit im probabilistischen Modell auch die Unsicherheit modellieren zu können, mit wie vielen anderen Instanzen eine Instanz der Wissensbasis in Beziehung steht (sog. Anzahlunsicherheit) und mit welchen Instanzen (Referenzunsicherheit), können PRM somit auch Unsicherheit in Bezug auf die relationale Struktur der Wissensbasis ausdrücken.

Einen sehr ähnlichen Ansatz stellt die objektorientierte probabilistisch-relationale Modellierungssprache (OPRML) von Howard dar [How09]. Ein grundlegender Unterschied ist das Aufsetzen auf einer Variante von OOBN, durch welche z. B. die explizite Definition von Schnittstellen für die durch Frames modellierten Klassen ermöglicht wird. Dies erleichtert das Zusammensetzen der lokalen Modelle zu einem probabilistischen Gesamtmodell. Die Modellierungssprache unterscheidet weiterhin explizit den relationalen Anteil des Modells, welcher framebasiert eine Wissensbasis beschreibt,

und den probabilistischen Anteil, welcher die Abhängigkeiten zwischen Attributen der Frames modelliert. Zusätzlich zur Anzahl- und Referenzunsicherheit in PRM können OPRML basierte probabilistische Modelle auch Existenzunsicherheit für Relationen berücksichtigen, indem die Existenzwahrscheinlichkeit einer Relation explizit als Attribut repräsentiert wird.

Prädikatenlogische Ansätze Einen noch ausdrucksmächtigeren FOPL Ansatz stellen die sog. Multi-Entity Bayesian Networks (MEBN) von Laskey [Las08] dar. Dieser erhöht die Ausdrucksmächtigkeit der Wissensbasis auf endlich axiomatisierbare Formelmengen der Prädikatenlogik. MEBN können somit beliebigen prädikatenlogischen Ausdrücken Wahrscheinlichkeiten zuordnen. Ähnlich zu den bisher genannten objektorientierten Ansätzen werden auch in MEBN lokale probabilistische Modelle zur Faktorisierung des Gesamtmodells genutzt. Allerdings muss eine Gruppierung von Zufallsvariablen hier nicht zwingend mit Objektbezug erfolgen, sondern es können allgemein inhaltlich zusammenhängende Aussagen gruppiert und über ein lokales probabilistisches Modell beschrieben werden. Eine solche Gruppe von Zufallsvariablen wird in einem sog. MEBN Fragment zusammengefasst, welches eine bedingte Wahrscheinlichkeitsverteilung definiert. Verschiedene solcher Fragmente können zu einer MEBN Theorie zusammengefasst werden. Die Zufallsvariablen eines MEBN Fragments stellen dabei zugleich logische Ausdrücke dar. Diese Ausdrücke können freie (prädikatenlogische) Variablen enthalten. Bei der Instanziierung des probabilistischen Gesamtmodells auf Basis der prädikatenlogischen Wissensbasis stellen diese Variablen die Verbindung zwischen Individuen der Wissensbasis und MEBN Fragmenten dar. Durch diese Verbindung wird festgelegt, welche MEBN Fragmente wie oft instanziiert werden für das Gesamtmodell. Über sog. Kontextknoten in MEBN Fragmenten können dabei noch weitere Bedingungen an die Wissensbasis bzgl. ihrer Instanziierung formuliert werden.

MEBN stellen dabei eine sehr allgemeine Modellierungssprache dar, aus welcher auch theoretische Erkenntnisse ableitbar sind. Sie beschränkt sich dabei nicht darauf, nur effizient berechenbare oder gar entscheidbare Modelle darstellen zu können. Für eine Anwendung ist daher ein Zuschneiden der Sprache notwendig. Dieser Ansatz wird von Costa [Cos05] und Carvalho [Car11]

verfolgt, welche eine Implementierung von MEBN in OWL 2 DL vorstellen. Die als PR-OWL bezeichnete probabilistische Erweiterung von OWL modelliert dabei die MEBN Sprachkonstrukte in OWL. Die Ausdrucksmächtigkeit der Implementierung, und somit die probabilistisch darstellbaren Aussagen, werden somit auf die Beschreibungslogik SROIQ(D) reduziert. Dabei werden beispielsweise Konzepte für MEBN Fragmente und Theorien, aber auch für Wahrscheinlichkeitsverteilungen und Zufallsvariablen definiert. Somit wird eine Brücke zwischen OWL und MEBN Modellen geschaffen. Das Vorgehen ermöglicht es, existierende OWL Ontologien nachträglich um probabilistische Anteile zu erweitern. Somit wird auch eine gewisse Aufteilung in relationale und probabilistische Anteile des Domänenmodells erreicht. Aus einer beschreibungslogischen OWL Wissensbasis heraus kann dann, wie oben beschrieben, ein probabilistisches Modell für die in MEBN Fragmenten modellierten Zusammenhänge erzeugt werden. PR-OWL (2) wurde auch als Kandidat für eine Repräsentation unsicherer Informationen im Semantic Web in Betracht gezogen.

2.2.5 Zusammenfassung zur Wissensrepräsentation

Im vorliegenden Abschnitt wurden unterschiedliche Ansätze zur Repräsentation von Domänenwissen vorgestellt und betrachtet. Ausgehend von den Anforderungen der objektorientierten Umweltmodellierung lag der Fokus dabei auf einem logikbasierten Formalismus, mit welchem semantische Wissensmodelle repräsentiert werden können. Für eine rein logische Formalisierung ohne die Repräsentation von unsicherheitsbehafteten Informationen ist dabei OWL 2 DL als Beschreibungslogik und Standard des Semantic Web der vielversprechendste Aufsatzpunkt. Zur strukturierten Repräsentation von unsicherheitsbehafteten Information in komplexen Domänen wurden weiterhin verschiedene kombiniert logisch-probabilistische Ansätze betrachtet. Diese setzen auf einem relationalen Modellanteil auf, z. B. dargestellt mittels einer Beschreibungslogik, und definieren über den Instanzen der Wissensbasis zu diesem relationalen Modell dann eine gemeinsame

Wahrscheinlichkeitsverteilung von Instanzattributen. Der Fokus der probabilistischen Modellierung liegt hier auf der Ermöglichung von Inferenz, daher werden i. A. nur nominale Merkmale als Attribute und diskrete Verteilungen betrachtet.

2.3 Umweltmodellierung und Wissensmodelle

Nach einer grundlegenden Darstellung der verschiedenen Herangehensweisen für eine Wissensmodellierung, z. B. im Bereich der KI allgemein, aber auch in der Softwareentwicklung, sollen in diesem Abschnitt konkrete, existierende Wissensmodelle mit Bezug zur objektorientierten Umweltmodellierung betrachtet werden. Dies betrifft sowohl andere Umweltmodelle als auch allgemeine Wissensbasen im Bereich der KI. Weiterhin werden die Top-Level Ontologien betrachtet, die z. B. existierenden Wissensbasen zum Zweck einer allgemeinen Strukturierung von Wissen zugrunde liegen. Schließlich werden auch einige spezialisierte Wissensmodelle mit Relevanz zur Umweltmodellierung betrachtet, welche z. B. spezifisches Wissen zu Aspekten wie Zeit oder Maßeinheiten repräsentieren.

2.3.1 Andere Umweltmodelle

Zunächst soll auf verwandte Ansätze der Umweltmodellierung und deren Techniken und Verfahren zur Wissensmodellierung eingegangen werden, anhand von relevanten Beispielen. Die Umweltmodellierung im Sinne der Erstellung von Umgebungsmodellen wird in verschiedenen Forschungs- und Anwendungsbereichen betrachtet und eingesetzt, darunter die Bereiche der Unterstützung von Situationsbewusstsein, des autonomen Fahrens und der Servicerobotik.

Viele der zuvor genannten logisch-probabilistischen Repräsentationssprachen für Wissen entstammen dabei dem Bereich der Unterstützung von Situationsbewusstsein. Das Ziel ist hier die Entwicklung kognitiver Assistenzsysteme, welche menschliches Situationsbewusstsein und Entscheidungsfindung durch die Darstellung von semantisch fundierten Lagebildern unterstützen. Auch die Anwendung des objektorientierten Umweltmodells in intelligenten Videoüberwachungssystemen [Bau09], zur maritimen Situationsanalyse [Fis10, Kuw12b, Fis16], Informationsfusion [Kuw17] oder zum Schutz kritischer Infrastrukturen [Bou16, Kuw18] fällt in diesen Bereich. Zur Unterstützung von Situationsbewusstsein werden z. B. PRM in [Pfe99] oder OPRML in [How09] eingesetzt. Dabei wird zunächst ein relationales Wissensmodell definiert und dieses dann anhand von aktuellen Beobachtungen und Sensordaten als eine Wissensbasis zur Zustandsrepräsentation instanziiert [How10]. PR-OWL wird beispielsweise für die Klassifikation von Schiffen in Assistenzsystemen eingesetzt [Las11].

Im Bereich des autonomen Fahrens wird eher von Umfeldmodellen gesprochen als von Weltmodellen. In solchen Umfeldmodellen werden die Informationen aus allen verfügbaren Sensoren eines Fahrzeugs zusammengefasst und integriert dargestellt. Ein wichtiger Teil der Modellierung ist dabei die Dynamik von Fahrsituationen, die häufig mittels Zustandsraummodellen sowie unterstützend kartenbasiert erfolgt. Eine explizite Modellierung von semantischem Wissen steht nur in einigen Fällen im Vordergrund. Dabei werden zum Teil nur einzelne Aspekte des autonomen Fahrens modellbasiert gelöst. Von Nienhüser [Nie14] werden z. B. bestimmte Fahrsituationen wie das Erkennen von Baustellen und relevanten Ampeln mittels Markov-Logik-Netzen und einem prädikatenlogischen Modell dieser Situationen gelöst. Es gibt weiterhin auch Ansätze, welche grundlegend die Verwendung semantischen Wissens vorsehen. Schamm nutzt in [Sch14] zum Beispiel ein semantisches Wissensmodell zur Erkennung von Fahrsituationen. Zur Wissensrepräsentation wird dabei OPRML als logisch-probabilistische Repräsentationssprache eingesetzt. In dieser Sprache wird ein probabilistisch-relationales Modell von Fahrzeugen und Fahrsituationen

erstellt. Dieses Modell kann mittels aktueller Informationen aus dem Umfeldmodell zu einem Bayes'schen Netz instanziiert werden, welches dann zur Analyse von Fahrsituationen durch probabilistische Inferenz dient.

Umweltmodelle im Bereich der Robotik

Im Bereich der Robotik wird vornehmlich der Begriff der Weltmodellierung verwendet. Wissensmodelle werden dabei zur Unterstützung von Aufgaben wie der Planung, Navigation, Aktionserkennung und Mensch-Roboter-Interaktion eingesetzt [Tho18]. Ein Ansatz der Weltmodellierung zur Navigation und Missionsplanung sind sog. semantische Karten [Gal05, Uhl13]. Diese Karten stellen dabei hybride Umweltmodelle dar, welche eine räumliche Topologie der Umgebung erstellen und diese mit symbolischen Instanzen eines semantischen Modells verbinden, z. B. mittels Verankerung¹ [Gal05] der Symbole in Sensorbeobachtungen. Das Wissensmodell wird dabei als Vorwissen bereitgestellt und modelliert unterschiedliche Räume sowie diejenigen Objekte, die in diesen Räumen axiomatisch enthalten sein müssen oder nicht enthalten sein dürfen. Ebenfalls werden topologische Beziehungen zwischen Räumen modelliert. Die Modellierung erfolgt mittels Beschreibungslogik in [Gal05] bzw. F-logic in [Uhl13] ohne die Modellierung von unsicherem Wissen. Das Vorwissen kann genutzt werden, um Räume über die in ihnen enthaltenen, aus Sensorbeobachtungen bekannten Objekte klassifizieren zu können [Gal05]. Ebenso kann für klassifizierte Räume abgeleitet werden, welche Objekte noch in ihnen erwartet werden können.

Wissensbasen, welche im Bereich der Servicerobotik verfügbar sind, werden in [Tho18] im Überblick dargestellt. Als eine der einflussreichsten Wissensbasen wird dabei KnowRob von Tenorth und Beetz [Ten13, Ten09, Ten10] genannt. Mit KnowRob wird ein umfassender Ansatz zur wissensbasierten

¹ Verankerung (englisch „Anchoring“) bezeichnet nach Coradeschi [Cor03] den Prozess, eine Verbindung zwischen den Sensordaten und den Symbolen einer symbolischen Repräsentation herzustellen und aufrechtzuerhalten, welche sich auf dasselbe physische Objekt beziehen. Diese Problemstellung ist eng verwandt mit der Aufgabe der Datenassoziation im Bereich des Trackings und stellt einen Spezialfall des Symbol Grounding Problems dar.

Weltmodellierung verfolgt. Auch hier werden semantische Karten genutzt, welche mit einem Wissensmodell dynamisch verknüpft werden [Ten10]. Im Vordergrund steht bei diesem Ansatz allerdings die Wissensverarbeitung für autonome Roboter, mit einem Fokus auf der robusten Planung und Steuerung von Handlungen in einer Haushaltsumgebung. Das entworfene System zur Wissensrepräsentation und -verarbeitung ist dabei für eine echtzeitnahe Ausführung auf einem Roboter ausgelegt.

Die Strukturierung des Wissensmodells in KnowRob ist inspiriert durch die Ontologie Cyc [Len95]. Für KnowRob wurde diese zugeschnitten und erweitert, um spezifisch die Aktionen eines Haushaltsroboters und von diesen Aktionen betroffene Objekte darstellen zu können. Dabei werden in einer Top-Level Ontologie Kategorien wie Ereignisse, Aktionen, Agenten, Objekte, Geräte und Orte als Konzepte modelliert. Diese Kategorien werden über Domänen-Konzepte spezialisiert, z. B. werden Aktion wie das Öffnen und Schließen von Behältnissen sowie das Aufnehmen und Ablegen von Objekten repräsentiert. Das Wissensmodell ist formal in OWL DL repräsentiert. Eine Axiomatisierung¹ besteht allerdings größtenteils nur in Bezug auf die modellierten Roboter-Aktionen, die von den Aktionen betroffenen Objekte sind nahezu rein taxonomisch und ohne Attribute beschrieben.

Zur Verankerung dieses symbolisch beschriebenen Wissens in den Sensorbeobachtungen eines Roboters sind ebenfalls ansichtsbasierte, subsymbolische Objektmodelle in KnowRob hinterlegt. Diese können genutzt werden, um aus mittels Sensorik erworbenen Umgebungsinformationen eine entsprechende Wissensbasis zu instanziiieren. In [Ten11] wird dabei ein Ansatz beschrieben, um derartige Objektmodelle semi-automatisiert unter Verwendung von Quellen im Internet in das Wissensmodell integrieren zu können. Dazu werden durch eine Suche entsprechende Objektbilder z. B. aus Online-shops bezogen und als Trainingsbeispiele für ein Klassifikationsmodell genutzt. Über zusätzlich verfügbare Informationen wie Produktbeschreibungen werden diese Objektmodelle ins Wissensmodell eingeordnet.

¹ In Bezug auf die auf der KnowRob Webseite (<http://knowrob.org/kb/knowrob.owl>, letzter Ab-ruf: 26.02.2020) verfügbare Ontologie.

Mittels Verfahren der Sprachverarbeitung kann das Wissensmodell weiterhin auch mit Handlungswissen gefüllt werden, welches die Ausführung von Alltagsaufgaben beschreibt. Dieses wird ebenfalls semi-automatisch aus Quellen im Internet erworben und in eine beschreibungslogische Form überführt [Kun10, Ten11]. Für die beiden semi-automatischen Vorgänge zum Erwerb von Wissen aus dem Internet ist ein menschliches Eingreifen z. B. zur Qualitätssicherung des Wissens oder zur Disambiguierung von Begriffen notwendig. Die Techniken werden daher eher als eine Unterstützung für den Menschen bei der Wissensmodellierung angesehen [Ten13].

Die Wissensrepräsentation in KnowRob erfolgt zunächst prinzipiell deterministisch. Mittels Bayesian Logic Networks [Jai11] ist allerdings ebenfalls eine Komponente zur Darstellung von probabilistischen Zusammenhängen und zur probabilistischen Inferenz in das System integriert. Für spezifische Teilaspekte kann somit eine Modellierung von Unsicherheiten erfolgen. Dies betrifft hauptsächlich Beziehungswissen und kann nur mittels diskreter Zufallsvariablen erfolgen. Die Instanziierung probabilistischer Teilmodelle erfolgt dabei bei Bedarf und aus der Wissensbasis heraus.

Neben KnowRob gibt es noch weitere Wissensbasen im Bereich der Servicerobotik. Zwei wichtige Beispiele sind das Ontology-based Unified Robot Knowledge (OUR-K) [Lim11] sowie die Open Robots Ontology [Lem11]. OUR-K von Lim et al. stellt dabei ebenfalls einen umfassenden Ansatz zur Weltmodellierung dar, welcher Aspekte der Welt auf unterschiedlichen Ebenen zusammenhängend repräsentiert. Dabei werden Merkmale von Objekten modelliert, Objekte selbst, Karten auf metrischer, topologischer und semantischer Ebene, räumliche und zeitliche Beziehungen von Objekten sowie Aufgaben und Handlungen eines Roboters. Das Modell ist dazu in fünf unterschiedliche Kategorien eingeteilt (wie Objekte), welche jeweils bis zu drei Ebenen besitzen (wie Objektteile, Objekte und Objektgruppen). Innerhalb dieser Struktur werden dann konkrete Konzepte modelliert (wie Tassen als

Objekte). Zwischen den Kategorien und Ebenen können Beziehungen unterschiedlicher Art bestehen, z. B. Teile-Ganzes-Beziehungen zwischen Objektteilen und den entsprechenden Objekten oder eine Zuordnung von Merkmalen zu Objektteilen. Merkmale sind auf symbolischer Ebene und auf subsymbolischer Ebene repräsentiert, wobei letztere in Sensordaten verankert¹ sind. Neue Sensorbeobachtungen können somit Aktualisierungen in der Wissensbasis bewirken, d. h. die Erzeugung neuer Konzeptinstanzen oder die Aktualisierung existierender Instanzen. Als Repräsentationssprache wird dabei OWL DL verwendet. Zusätzlich werden prädikatenlogische Regeln definiert. Diese dienen der sog. Wissensassoziation, mit welcher zur Laufzeit unterschiedliche Fakten (Instanzen der Wissensbasis) miteinander verknüpft werden, um einen Roboter bei der Ausführung seiner Aufgaben zu unterstützen.

Lemaignan [Lem12] beschäftigt sich zunächst grundlegend mit dem Thema der Wissensrepräsentation für Serviceroboter. Dabei werden unterschiedliche existierende Ansätze, darunter KnowRob und OUR-K, betrachtet und analysiert. Alle betrachteten Ansätze werden anhand eines in [Lem11] entwickelten Klassifizierungsschemas für Wissensrepräsentationssysteme eingeordnet. Darauf aufbauend wird von Lemaignan die Open Robots Ontology (ORO, [Lem11, Lem12]) definiert. ORO stellt eine OWL 2 DL Wissensbasis für Serviceroboter dar, welche die aktive Verwaltung und Abfrage des erhaltenen Wissens unterstützt. Zur Darstellung von Vorwissen enthält ORO ein Wissensmodell mit Alltagswissen im Umfang von 56 Klassen und 60 Relationen. Als Top-Level Ontologie wird OpenCyc eingesetzt. ORO unterstützt im Speziellen die dialogbasierte Interaktion mit einem Serviceroboter. Dabei ist es z. B. möglich, dem Roboter unbekannte Objekte von einem Menschen solange beschreiben zu lassen, bis diese innerhalb der Wissenstaxonomie von ORO ihrem Typ nach eingeordnet werden können [Lem12]. Auf diese Weise können auch Begriffe der menschlichen Sprache in den Beobachtungen bzw. im Wissen des Roboters verankert² werden.

¹ im Sinne von Symbol Grounding

² im Sinne von Symbol Grounding

2.3.2 Existierende Wissensbasen und -modelle

Weiterhin relevant für die Wissensrepräsentation in Umweltmodellen sind auch Arbeiten, die explizit dem Aufbau von komplexen Wissensbasen dienen, welche z. B. Allgemein- und Alltagswissen repräsentieren. Derartige Wissensbasen dienen oft der Erforschung und Entwicklung neuartiger informationsverarbeitender Systeme und werden z. B. eingesetzt, um das Verstehen natürlicher Sprache, die gezielte Suche nach Informationen oder das Ziehen von Schlussfolgerungen in Alltagssituationen zu unterstützen. Ein Beispiel für solch eine Wissensbasis ist die Ontologie Cyc [Len95], welche im gleichnamigen Projekt seit Langem entwickelt wird. Weitere Beispiele solcher Wissensbasen sind WordNet [Mil95], ConceptNet [Liu04] oder Projekte wie DBpedia [Leh15] und YAGO [Reb16], welche menschliches Allgemeinwissen erfassen und auf formalisierte Weise im Internet frei verfügbar machen. Diese Wissensbasen stellen dabei sog. Wissensgraphen bzw. Linked (Open) Data dar, d. h. umfangreiche semantische Netze.

Für die Umweltmodellierung ist vor allem die Frage interessant, inwieweit das in solchen Wissensbasen repräsentierte Wissen in einem Hintergrundwissensmodell genutzt werden kann. Hier spielen Aspekte wie die Darstellungsform und Formalisierung des Wissens, der kognitive Bias der Modellierung sowie die Qualitätssicherung erstellter Modelle eine Rolle. Weiterhin ist die grundlegende kategorische Strukturierung des repräsentierten Wissens von Bedeutung. Zu diesem Zweck wird nachfolgend eine Auswahl relevanter Wissensbasen und Strukturierungsansätze näher betrachtet.

WordNet [Mil95] ist eine frei verfügbare lexikalische Datenbank, welche Begriffe bzw. Gruppen bedeutungsgleicher Begriffe als Konzepte eines taxonomischen Wissensmodells beschreibt und mittels semantischer Relationen in Beziehung setzt. Neben Synonymen werden Ober- und Unterbegriffe (Hyper- und Hyponyme), Teile-Ganzes-Beziehungen (Meronyme und Holonyme) sowie Gegensätze (Antonyme) im Wissensmodell repräsentiert. Weiterhin werden Homonyme (gleichlautende Begriffe mit unterschiedlicher Bedeutung) durch die genannte Gruppierung bedeutungsgleicher

Begriffe unterschieden. Die Strukturierung von Wissen in WordNet orientiert sich im Wesentlichen an diesen semantischen Relationen. WordNet wird häufig im Bereich der Verarbeitung natürlicher Sprache eingesetzt, insbesondere zur Disambiguierung von Begriffen.

Eine ähnlich aufgebaute Wissensbasis stellt ConceptNet [Liu04] dar, welches aus dem Open Mind Common Sense Projekt hervorgegangen ist. Ziel dieses Projekts war es, eine möglichst große Menge an Allgemeinwissen in einem web-basierten Crowdsourcing Ansatz zu erfassen. Das erfasste Wissen wird in Form von einfach gehaltenen, natürlichsprachlichen Sätzen dargestellt. Für ConceptNet werden diese Sätze automatisch aufbereitet und als ein semantisches Netz formalisiert dargestellt. Die erzeugten Konzepte orientieren sich dabei an zusammengesetzten Ausdrücken und können z. B. Nominalphrase, Verbalphrasen oder Attributphrase repräsentieren. Im Gegensatz zu WordNet werden neben semantischen Relationen noch über 20 weitere Typen von Relationen in ConceptNet unterstützt. ConceptNet ist frei verfügbar und stellt eine Form von Linked Open Data dar.

Der Begriff Linked Data nach Berners-Lee [Ber06], bzw. Linked Open Data, falls frei verfügbar, beschreibt in seiner Reinform untereinander in Beziehung stehende Daten, welche über eindeutige Bezeichner identifiziert werden. Die Bezeichner fungieren dabei zugleich als Identifikatoren für Ressourcen im World Wide Web, unter welchen die mit einem Bezeichner verbundene, intendierte Bedeutung, z. B. in Form einer Beschreibung, hinterlegt wird. Auch die Arten der verwendeten Beziehungen zwischen Daten werden auf diese Weise beschrieben. Als Teil des Semantic Web wird Linked Data mittels RDF¹ und ggf. OWL als Repräsentationssprachen dargestellt.

Ein Beispiel für Linked Open Data ist die Wissensbasis des DBPedia Projekts [Leh15], welches aus Wikipedia extrahiertes Wissen aufbereitet und formal repräsentiert. Zur Einordnung des zumeist aus den strukturierten Anteilen von Wikipedia-Seiten extrahierten Wissens wird eine eigens erstellte Ontologie verwendet, die allerdings nicht die Kriterien einer allgemeinen Top-Level Ontologie (wie beispielsweise Aufgabenunabhängigkeit)

¹ Resource Description Framework, s. Abschnitt 2.2.3

erfüllt. Die erstellte Wissensbasis ist sehr umfangreich und enthält, analog zu Wikipedia, Wissen zu vielen unterschiedlichen Domänen. Dabei zählen insbesondere Personen und Orte zu den am häufigsten repräsentierten Informationen. Ein ähnliches Vorgehen wird auch von Projekt YAGO [Reb16] verfolgt. Auch hier wird Wissen aus Wikipedia extrahiert und strukturiert dargestellt, wobei besonderer Wert auf die Qualität der extrahierten Daten gelegt wird. Zur taxonomischen Strukturierung des extrahierten Wissens wird WordNet verwendet.

In den zuvor genannten Wissensbasen wird Allgemeinwissen über die Welt und teilweise Domänenwissen formal dargestellt. Viele der Wissensbasen sind untereinander vernetzt und stellen ihr Wissen in Form von RDF Tripeln frei zur Verfügung. Durch die Art des enthaltenen Wissens, z. B. bzgl. Detailgrad und Formalisierung, sind diese Wissensbasen nicht direkt als Hintergrundwissensmodell für die Umweltmodellierung geeignet. Sie können jedoch wertvollen Quellen für die Erstellung eines Modells und dessen semi-automatische Ergänzung darstellen.

Top-Level Ontologien

Neben den eigentlichen Inhalten eines Wissensmodells ist dessen grundlegende kategorische Strukturierung, nach welcher Wissen angeordnet wird, ein wesentlicher Aspekt für die Umweltmodellierung. Für Ontologien wird eine derartige Strukturierung im Idealfall in Form einer Top-Level Ontologie beschrieben. Viele der formaleren Wissensmodelle definieren explizite Top-Level Ontologien für ihre Wissensbasen. Da Top-Level Ontologien mit Hinblick auf Wiederverwendbarkeit entworfen werden, stellen sie bzgl. der möglichen Strukturierung der Wissensrepräsentation für die Umweltmodellierung relevante Literatur dar.

Das bereits erwähnt Projekt Cyc [Len95] definiert eine umfangreiche Wissensbasis, welche auf einer explizit formulierten Top-Level Ontologie basiert. Unterhalb dieser Top-Level Ontologie sind sog. Mikrotheorien auf unterschiedlichen Ebenen angesiedelt, welche auf tieferen Ebenen getrennt

voneinander spezifische Anwendungsbereiche beschreiben. Top-Level Ontologie und Wissensbasis werden in einer eigenen Repräsentationssprache namens CycL dargestellt, welche in Teilen eine Logik höherer Stufe darstellt [Mat06]. Das Projekt stellt weiterhin eine eigene Inferenzmaschine für diese Sprache bereit. Die Top-Level Ontologie von Cyc unterscheidet inhaltlich Kategorien wie Individuen von Sammlungen, anfassbare von teilweise nicht anfassbaren Individuen, räumliche von zeitlichen Individuen usw. Die Wissensbasis an sich beschreibt Allgemeinwissen sowie domänen- und anwendungsspezifisches Wissen für viele Teilbereiche. Wissensbasis und Top-Level Ontologie sind proprietär, für einen Zeitraum existierte jedoch mit OpenCyc auch eine im Umfang reduzierte, frei zugängliche Variante.

Eine weitere Top-Level Ontologie ist mit der Suggested Upper Merged Ontology (SUMO) [Nil01] gegeben. Diese Top-Level Ontologie wurde als Verschmelzung von mehreren vorausgehenden Top-Level Ontologien erstellt, darunter Ontologien von Sowa [Sow99] sowie von Russell und Norvig [Rus10]. Die Ontologie ist in einer Version des Wissensaustauschformats KIF¹ beschrieben. Die Top-Level Ontologie unterscheidet inhaltlich Physisches von Abstraktem. Als Physisches werden dabei Objekte von Prozessen sowie ganzheitliche Objekte von Sammlungen unterschieden. Als Abstraktes werden Attribute von Relationen unterschieden etc. Die Anwendungsgebiete der Top-Level Ontologie liegen in den Bereichen Suche, Linguistik und Schlussfolgern. Die Top-Level Ontologie wird zusätzlich durch entsprechende Domänen-Ontologien für spezifische Anwendungsbereiche ergänzt und ist frei verfügbar.

Eine weitere, ebenfalls frei verfügbare Top-Level Ontologie stellt DOLCE [Mas03] dar. Diese Top-Level Ontologie wurde im WonderWeb Projekt entwickelt, welches die Erstellung einer Bibliothek von Ontologien zum Ziel hatte. DOLCE diente in dieser Bibliothek als Ausgangspunkt für die Entwicklung und Integration weiterer grundlegender Ontologien. DOLCE selbst ist eine reine Top-Level Ontologie, welche in Prädikatenlogik beschrieben und stark axiomatisiert ist. Neben Ausdrucksstärke stand bei der

¹ Knowledge Interchange Format

Entwicklung von DOLCE auch die Fundierung von Entwurfsentscheidungen auf Prinzipien der formalen Ontologie im Vordergrund¹. In der Top-Level Ontologie wird Abstraktes von Qualitäten sowie raumzeitlichen Entitäten unterschieden. Entitäten existieren dabei entweder zu jedem einzelnen Zeitpunkt vollständig oder zu jedem Zeitpunkt nur teilweise und dafür in der Zeit. Weiterhin wird Physisches von Nichtphysischem und Handelndes von Gegenständlichem unterschieden. DOLCE als Top-Level Ontologie ist dabei insgesamt auf eine Modellierung von Kategorien ausgerichtet, welche menschlicher Sprache und Allgemeinwissen zugrunde liegen.

Die genannten Top-Level Ontologien stellen strukturierte Ansätze dar, mittels derer sich Domänenwissen in einem Hintergrundwissensmodell inhaltlich gegliedert repräsentieren lässt. Die Ansätze unterscheiden sich dabei in Bezug auf die Art, wie solches Wissen grundsätzlich kategorisiert wird. Für alle genannten Ansätze existiert eine Formalisierung in OWL DL, für SUMO und DOLCE ist diese frei verfügbar.

Spezialisierte Wissensmodelle

Neben der kategorischen Strukturierung eines Wissensmodells existieren weitere Aspekte, die domänenübergreifenden Charakter haben und somit unabhängig von einer konkreten Anwendung beschrieben werden können. Dazu zählen z. B. die Darstellung von Raum, Zeit und Einheiten. Für Raum und Zeit betrifft dies die Darstellung punktueller Informationen (wie Positionen oder Zeitpunkte) und regionenbezogener Informationen (Gebiete, Zeitintervalle). Weiterhin ist auch die Definition von Beziehungen zwischen solchen Informationen betroffen (z. B. räumliche oder zeitliche Nachbarschafts-, Enthaltenseins- und Unterschiedlichkeits-Beziehungen).

Raum Die Darstellung von Raum bzw. Ort besitzt ebenfalls unterschiedliche Aspekte. Einerseits können mit Positionen Orte für Entitäten angegeben werden. Dies kann z. B. metrisch mit Bezug zu einem Koordinatensystem erfolgen. Andererseits kann Raum nach Bateman und Farrar [Bat06] auch als

¹ vgl. Abschnitt 2.2.3 zur OntoClean Methodik

eine grundlegende ontologische Qualität betrachtet werden und dabei auf unterschiedliche Arten konzeptualisiert und formalisiert werden. Hier spielen räumliche Beziehungen unterschiedlicher Arten eine wichtige Rolle.

Soll für ein betrachtetes Objekt seine Position angegeben werden, so besteht ein häufiges Vorgehen darin, diese Position mit einem Punkt in einem entsprechenden Koordinatensystem zu identifizieren. Dies kann geometrisch erfolgen, unter Verwendung eines zwei- oder dreidimensionalen kartesischen Koordinatensystems. Die einzelnen Koordinaten einer Position werden dabei metrisch als Längen mit entsprechender Maßeinheit angegeben. Neben geometrischen Koordinatensystemen können auch geographische Koordinatensysteme genutzt werden, z. B. um die Position von Objekten auf der Erdoberfläche anzugeben. Positionen werden hier häufig mittels zweier Koordinaten beschrieben. Für eine eindeutige Interpretation solcher Angaben wird allerdings weiterhin ein sog. geodätisches Datum benötigt, welches Ursprung und Orientierung eines geographischen Koordinatensystems in Bezug auf den Erdkörper festlegt. Zusammen werden das Koordinatensystem und das geodätische Datum als Koordinatenreferenzsystem bezeichnet. Beispiele für solche geodätischen Referenzsysteme sind das World Geodetic System 1984 (WGS84) [NIM00] sowie das UTM-System¹. In WGS84 werden Positionen von Objekten auf der Erdoberfläche über die Angabe der geographischen Länge und Breite beschrieben.

Allgemein lassen sich lokale bzw. relative Koordinatensysteme von globalen oder Weltkoordinatensystemen unterscheiden. Durch die Angabe eines geodätischen Datums wird ein lokales geographisches Koordinatensystem z. B. zu einem globalen Koordinatensystem. Diese Unterscheidung gilt ebenso für geometrische Koordinatensysteme. Beispielsweise müssen Ortsangaben in den lokalen Koordinatensystemen verschiedener Serviceroboter für einen Vergleich oder eine weitere Verarbeitung zunächst in ein gemeinsames Weltkoordinatensystem umgerechnet werden. Zu diesem Zweck können entsprechende Koordinaten-Transformationen genutzt werden.

¹ Universal Transverse Mercator

Die Darstellung von Positionen mittels metrischer Koordinatensysteme ist für eine technische Informationsverarbeitung hilfreich. In Situationen des menschlichen Alltags spielt diese Art der Ortsdarstellung allerdings nur eine untergeordnete Rolle. Hier steht eine andere Art der Referenzierung von Ort und Raum im Vordergrund, welche von qualitativer Natur ist und sich räumlicher Beziehungen bedient [Bat06]. Dies spiegelt sich auch in der menschlichen Sprache wieder. Diese Art der Ortsdarstellung ist somit auch für eine Repräsentation von raumbezogenen Vorwissen auf semantischer und pragmatischer Ebene relevant.

Hierbei wird Raum als eine grundlegende ontologische Qualität aufgefasst. Die Instanzen dieser Qualität stellen z. B. räumliche Regionen dar. Regionen können gegenüber Punkten dabei als eine natürliche Repräsentation und ein kognitiv motiviertes Grundprimitiv zur Darstellung von Raum betrachtet werden [Bat06]. Um bei diesem Vorgehen raumbezogene Aspekte und Eigenschaften von relevanten Entitäten einer Domäne beschreiben zu können, werden diese Objekte in Abstraktion ihrer weiteren Eigenschaften mit den von ihnen eingenommen räumlichen Regionen identifiziert.

Um Wissen über räumliche Regionen (und somit auch die raumbezogenen Aspekte von Entitäten) in Form von Aussagen darstellen zu können, werden räumliche Relationen benötigt. Diese Relationen beschreiben dabei qualitatives Wissen. Als grundlegende Relationen werden in [Bat06] Teile-Ganzes-Beziehungen, Verbundenheit und Gleichheit zwischen Regionen genannt sowie Beziehungen zwischen Entitäten und Regionen, welche zur Verortung der Entitäten dienen. Als Arten von Relationen lassen sich topologische Relationen von Richtungs- und Abstandsbeziehungen unterscheiden [Pul88]. Letztere beinhalten Beziehungen wie „vor“, „hinter“, „links von“ oder „nahe bei“ und stellen meist symbolische Relationen dar. Topologische Relationen wie „gleich“, „berührt“, „enthält“, „überlappt“ etc. können dagegen mittels Logik formal in ihrer Bedeutung definiert werden. Somit lassen sie sich in Kalkülen wie dem Region Connection Calculus (z. B. als RCC8) [Ran92] zum raumbezogenen Schlussfolgern verwenden. Einen umfassenden Ansatz zur formalen Beschreibung der möglichen topologischen Beziehungen zwischen zwei gegebenen (zweidimensionalen) räumlichen Regionen stellt das sog.

DE-9IM¹ Modell [Cle93] dar. In diesem Modell können formal 512 verschiedene Beziehungen zwischen Regionen unterschieden werden. Diese formalen Beziehungen werden genutzt um verallgemeinerte, vor allem dimensionsunabhängige, präzise Relationen für Regionen zu definieren.

Für die Darstellung von Raum in existierenden Umweltmodellen, wie z. B. den zuvor vorgestellten, lassen sich ebenfalls die genannten unterschiedlichen Betrachtungsweisen von Raum erkennen. So werden z. B. lokale metrische Karten über topologische Beziehungen verknüpft, um eine globale Repräsentation des relevanten Raums zu erreichen. Durch die Verknüpfung der menschlichen Vorstellung von Raum, wie über Sprache ausgedrückt, mit der technischen Repräsentation entstehen somit semantische Modelle.

Auch einige der genannten Top-Level Ontologien, darunter SUMO und Cyc, beinhalten bereits einige Formalisierungen der Art und Weise, wie Raum und räumliche Positionen betrachtet werden, und definieren entsprechende räumliche Beziehungen [Bat06]. Andere, wie DOLCE, legen nur allgemein die Art und Weise fest, wie Raum als eine ontologische Qualität repräsentiert wird und überlassen die detaillierte Modellierung im Bedarfsfall untergeordneten, detaillierteren Ontologien.

Zeit Zur Modellierung von Zeit existieren viele unterschiedliche ontologische Ansätze. Einen im Bereich des Semantic Web relevanten Ansatz stellt die Ontologie OWL-Time dar [W3C20], eine in OWL 2 DL repräsentierte Formalisierung von Zeitintervallen und Zeitpunkten sowie zeitlichen Relationen. Der Ontologie liegt eine prädikatenlogische Axiomatisierung zugrunde, welche angepasst in Beschreibungslogik übernommen wurde. Zeitpunkte werden dabei als Spezialfall eines Zeitintervalls mit Länge 0 betrachtet. Zur Repräsentation von Zeitpunkten mit Datum wird in OWL-Time u. a. auf zwei Grundprimitiven aus OWL aufgebaut, welche XML Datentypen entsprechen. Einen alternativen Ansatz stellt das Date-Time Vocabulary [Lin12] dar, für welches ebenfalls eine OWL 2 Fassung existiert. Auch einige Top-Level Ontologien machen Aussagen über die Repräsentation von Zeit. Für DOLCE gilt z. B. dieselbe allgemeine Herangehensweise wie für die

¹ Dimensionally Extended nine-Intersection Model

Darstellung von Raum, in welcher Zeit unspezifisch als eine der möglichen Qualitäten einer Entität behandelt wird, welche Werte innerhalb einer zeitlichen Region besitzt. Eine weitere Spezifizierung dieser Grundstruktur wird untergeordneten Ontologien überlassen. Die Konzepte von Zeit und Raum werden in DOLCE allerdings in der grundlegenden Strukturierung zur Unterscheidung von Kategorien genutzt. Weiterhin können auch die Beziehungen zwischen Zeitintervallen und Zeitpunkten formal durch zeitliche Relationen („vor“, „nach“, „enthält“ etc.) beschrieben werden. Auf Basis solcher Relationen kann dann mittels temporaler Kalküle wie Allens Intervallalgebra [All83] temporal geschlussfolgert werden.

Maßeinheiten Ein weiterer wichtiger Aspekt für die Umweltmodellierung ist die einheitenbehaftete Darstellung von erfassten Werten, z. B. in Bezug auf die Merkmale beobachteter Objekte. In einem Modell kann diesbezüglich Wissen über unterschiedliche existierende Einheiten für physikalische Größen und mögliche Konvertierungen zwischen diesen Einheiten dargestellt werden. Es existieren unterschiedliche Modelle, welche diese Thematik betrachten. Ein Teil dieser Modelle wird von Keil und Schindler [Kei19] gegenübergestellt und verglichen. Eines dieser Modelle ist die sog. Quantities, Units, Dimensions and Data Types¹ (QUDT) Ontologie, ein NASA initiiertes Projekt zur Beschreibung von physikalischen Größen, ihren Einheiten und den Zusammenhängen zwischen unterschiedlichen Größen. Auch Systeme von Größen und Einheiten werden betrachtet. Unter anderem werden in QUDT physikalischen Größen anwendbare Einheiten zugeordnet sowie Konversionen zwischen unterschiedlichen Einheiten für eine physikalische Größe beschrieben. Dabei werden auch Einheiten für raum- und zeitbezogene Größen beschrieben. Das Modell ist in einer in OWL formalisierten Fassung verfügbar. Eine weitere Ontologie für Maßeinheiten wird von Rijgersberg definiert [Rij13]. Die Ontologie ist in OWL 2 beschrieben und betrachtet ebenfalls physikalische Größen sowie für sie anwendbare Einheiten. Dabei werden explizit auch Präfixe (wie Kilo, Milli etc.) für Einheiten betrachtet und die Faktoren für eine Konvertierung zur Einheit ohne Präfix modelliert.

¹ <http://www.qudt.org> (letzter Abruf: 13.05.2020)

Ebenso werden Konvertierungen zwischen allgemeinen Einheiten beschrieben. Auch Skalenniveaus werden modelliert. Die Kategorisierung der Ontologie wird mit der Strukturierung der Top-Level Ontologie DOLCE verglichen, wobei einige Abweichungen festgestellt werden. Eine mögliche Integration in DOLCE wird daher als interessanter Aspekt beschrieben, der aber noch genauer untersucht werden muss.

2.3.3 Zusammenfassung zu existierenden Wissens- und Umweltmodellen

Es existieren zahlreiche formale Wissensmodelle und -basen, welche im Bereich der künstlichen Intelligenz zur Unterstützung von Anwendungen eingesetzt werden können. Diese Wissensmodelle stellen wertvolle Quellen für bereits formalisierte Informationen dar. Die konkrete Anwendbarkeit muss jedoch im Einzelfall in Bezug auf die Anforderungen eines Anwendungsfalls, die dort betrachtete Domäne sowie den zugrunde gelegten Bias (bzgl. Aspekten wie Abstraktionsniveau etc.) geprüft werden.

Die Wissensmodelle setzen unterschiedliche Formalismen zur Repräsentation von Wissen ein, wobei auch hier vermehrt OWL genutzt wird. Weiterhin werden unterschiedliche grundlegende Kategorisierungen in Form von Top-Level Ontologien angenommen. Top-Level Ontologien stellen dabei vielversprechende Ausgangspunkte zur Entwicklung von nichttrivialen Domänenmodellen dar. Spezialisierte Wissensmodelle betrachten detailliert spezifische Aspekte wie die Darstellung von Ort, Zeit und Maßeinheiten. Die Wiederverwendung von zumindest Teilen solcher Modelle stellt ebenfalls einen Mehrwert dar, muss jedoch auch im Einzelfall geprüft werden.

Im Bereich der Umweltmodellierung nutzen andere Ansätze ebenfalls logische oder logisch-probabilistische Sprachen zur Repräsentation von Domänenwissen. Die erstellten Domänenmodelle sind dabei meistens sehr speziell auf eine Domäne zugeschnitten und dienen häufig zur Erkennung vorgegebener Situationen. Dies gilt z. B. für Ansätze aus dem Bereich des autonomen Fahrens. Allgemein dienen die Umweltmodelle häufig der Unterstützung von Situationsbewusstsein, indem sie z. B. das Ziehen von Schlussfolgerungen ermöglichen. Komplexere Wissensmodelle werden im Bereich der Servicerobotik eingesetzt. Diese Modelle sollen Serviceroboter intelligentes autonomes Verfahren ermöglichen, z. B. bei der Ausführung von Alltagsaufgaben. Mit KnowRob existiert dabei eine umfangreiche formale Wissensbasis, welche sowohl Alltagswissen bzgl. menschlicher Handlungen als auch Informationen für eine Erkennung von Objekten beinhaltet bzw. semi-automatisiert erwerben kann. Eine Darstellung von probabilistischen Informationen wird allerdings auch hier nur zum Zwecke des Schlussfolgerns unterstützt, auf Basis einer Teilmenge des Modells. Auch folgen die semi-automatisch erworbenen Modellanteile nicht notwendigerweise Prinzipien der formalen Ontologie zur Strukturierung von Wissen.

2.4 Umweltmodellierung für offene Welten

In dieser Arbeit wird als ein zentrales Thema die adaptive Umweltmodellierung betrachtet. Diese betrifft die Fragestellung, wie ein Umweltmodell dazu in die Lage versetzt werden kann, sein genutztes Wissensmodell adaptiv an eine beobachtete Situation anzupassen. Neben der Fähigkeit, den Bedarf für eine solche Anpassung festzustellen, muss ein Umweltmodell zu diesem Zweck zu konkreten Ergänzungen und Anpassungen seines Hintergrundwissensmodells befähigt werden. Dabei geht die adaptive Umweltmodellierung davon aus, dass ein bereits existierendes Wissensmodell anzupassen ist, und nicht ein Modell vollständig neu zu erstellen ist. Die Anpassungen eines Hintergrundwissensmodells finden somit auf der Ebene der bisher im

Modell enthaltenen Konzepte statt. Ergänzungen des Modells betreffen dabei das Erlernen neuer Konzepte auf Basis von in der Umgebung beobachteten Entitäten. Weiterhin ist von Interesse, nach welchen Prinzipien solche Erweiterungen eines Modells stattfinden sollen. In Bezug auf die genannten Aspekte stellt dieser Abschnitt relevante Literatur vor. Da das Thema der adaptiven Umweltmodellierung eine spezifische Problemstellung auf Basis der objektorientierten Umweltmodellierung darstellt, sind hiervon verschiedene Bereiche betroffen, die allerdings nur im Überblick vorgestellt werden. Dabei wird in Abschnitt 2.4.1 zunächst das Thema des maschinellen Konzeptlernens betrachtet. Abschnitt 2.4.2 gibt anschließend einen Überblick über das Thema des Ontologie-Lernens. In Abschnitt 2.4.3 werden weiterhin kognitive Architekturen in Bezug auf die adaptive Umweltmodellierung betrachtet. Abschnitt 2.4.4 stellt schließlich zwei spezifische Ansätze mit Bezug zur adaptiven Umweltmodellierung vor.

2.4.1 Konzeptlernen

Das Erlernen neuer Konzept stellt eine zentrale Aufgabe der adaptiven Umweltmodellierung dar. Als Lernbeispiele, auf Basis derer neue Konzepte definiert werden sollen, dienen dabei in der Umgebung beobachtete und anschließend im Weltmodell repräsentierte Entitäten und ihre Eigenschaften. Diese Eigenschaften werden im Fall des objektorientierten Umweltmodells in Form von Wahrscheinlichkeitsverteilungen beschrieben, was z. B. gegenüber dem klassischen Konzeptlernen eine erweiterte Ausgangssituation darstellt. Die nachfolgende Darstellung des klassischen Konzeptlernens basiert auf [Kuw10].

Klassisches Konzeptlernen

Der klassische Ansatz zum Konzeptlernen befasst sich mit dem Lernen von booleschen Funktionen aus Beispielen [Mit97]. Ein Konzept wird dabei als eine boolesche Funktion betrachtet, welche Instanzen, die durch ihre Attributwerte repräsentiert werden, auf einen Wert von 1 (Konzeptzugehörigkeit) oder 0 (Nicht-Zugehörigkeit) abbildet. Die Menge der möglichen Instanzen

wird somit durch das kartesische Produkt der betrachteten Attributdomänen definiert, die oft aus diskreten Werten bestehen. Jede Instanz in der Menge der Trainingsdaten ist dabei als positives oder negatives Beispiel des Konzepts gekennzeichnet. Um ein Zielkonzept zu erlernen, werden die Konzepte als Hypothesen dargestellt, d. h. als Konjunktionen von Einschränkungen an die zulässigen Attributwerte. Dabei kann für ein bestimmtes Attribut z. B. jeder beliebige Wert erlaubt sein oder auch nur ein bestimmter Wert. Die Aufgabe des Konzeptlernens besteht dann darin, eine Hypothese zu finden, die mit den Trainingsdaten übereinstimmt. Diese Aufgabe kann als gezielte Suche im Hypothesenraum durchgeführt werden unter Ausnutzung einer Ordnung der Hypothesen bzgl. ihrer Allgemeinheit. Eine Hypothese gilt dabei als allgemeiner als eine andere, wenn die Menge der für sie zulässigen Instanzen eine Obermenge zur Menge der zulässigen Instanzen der anderen Hypothese darstellt. Basierend auf dieser Ordnung wurden verschiedene Lernalgorithmen für Konzepte entwickelt, darunter der Versionsraum-Algorithmus¹ von Mitchell [Mit79].

Induktive Inferenz Der induktive Bias des klassischen Konzeptlernens wird teilweise bereits durch die gewählte Struktur der Hypothesenrepräsentation bestimmt. Ist beispielsweise ein Zielkonzept nicht als Hypothese darstellbar, so kann es folglich auch nicht gelernt werden.

Für die allgemeine Aufgabe, aus Beispielen zu lernen, wird eine Menge von Stichproben oder Trainingsdaten $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ als gegeben angenommen, wobei x_i den beobachtbaren Teil der Daten und y_i eine Bewertung dieser Daten darstellt. Soll ein funktionaler Zusammenhang zwischen den x_i - und y_i -Werten gelernt werden, so wird diese Aufgabe im Bereich der Statistik als Regression und im Bereich des maschinellen Lernens als überwachtetes Lernen bezeichnet [Grü07]. Der speziellere Fall, in welchem die y_i -Werte auf eine endliche Menge beschränkt sind, wird als Klassifikation oder, im Speziellen, als Konzeptlernen bezeichnet.

¹ Englisch: Version Space

Das automatische Lernen aus einer kleinen Anzahl von Beispielen ist eine schwierige Aufgabe, insbesondere wenn die resultierende funktionale Beziehung oder der Klassifikator auch in der Lage sein soll, bisher ungesehene Daten gut vorherzusagen (sog. Generalisierungsfähigkeit). Für ein erfolgreiches Lernen sind neben den Trainingsdaten somit noch weitere Annahmen bzgl. des gegebenen Problems notwendig. Diese Annahmen können einen starken Einfluss auf die inferierte Generalisierung haben und werden daher als induktiver Bias bezeichnet [Mit80]. Ein prominentes Beispiel für den induktiven Bias beim Konzeptlernen stellt die Struktur des Raums der möglichen Hypothesen dar. Da Inferenzverfahren beim Lernen die Zielhypothesen nur aus diesem Raum auswählen können, sind nicht darstellbare Hypothesen daher a priori ausgeschlossen. Die Struktur des Hypothesenraums bzw. der induktive Bias muss somit auch in der adaptiven Umweltmodellierung beachtet werden.

Hierarchisches Konzeptlernen

Mit dem Erlernen von Konzepten beschäftigt sich auch das Gebiet der numerischen Taxonomie [Sok66], welches in [Kuw12a] betrachtet wurde. Dieses Gebiet betrifft die biologische Taxonomie und wurde ursprünglich entwickelt, um eine objektive Taxonomie für biologische Organismen anhand von quantitativ erfassbaren diskreten Merkmalen dieser Organismen erstellen zu können. Das methodische Ziel ist dabei, eine gegebene Menge von Objekten anhand der quantitativen Ähnlichkeit ihrer Merkmale unüberwacht in Gruppen einzuteilen. Diese Gruppen können wiederum hierarchisch angeordnet sein. Damit wird in der numerischen Taxonomie bereits eine Art der agglomerativen hierarchischen Clusteranalyse umgesetzt. Die numerische Taxonomie definiert dazu unterschiedliche Maße, mit denen die Ähnlichkeit von Objekten aufgrund ihrer Merkmale bewertet werden kann.

Eine tatsächliche Beschreibung der erzeugten Gruppen im Sinne einer Konzeptdefinition wird in der numerischen Taxonomie allerdings nicht erzeugt.

Eine solche Beschreibung führen allerdings die Methoden der konzeptuellen Clusteranalyse¹ von Fischer mit COBWEB [Fis87] und seinen Erweiterungen für kardinale Attribute (z. B. CLASSIT [Gen89]) ein. Die konzeptuelle Clusteranalyse hat dabei zum Ziel, gegebene Daten (Objekte und deren diskrete Attribute) auf eine verständliche Weise zusammenzufassen und zu abstrahieren [Fis87]. Zu diesem Zweck werden für Cluster Beschreibungen erzeugt, welche das durch ein Cluster dargestellte Konzept im Sinne einer Definition beschreiben. Die Beschreibung erfolgt probabilistisch als eine Statistik über die bisher beobachteten Attributwerte der Instanzen dieses Clusters und wird als ein probabilistisches Konzept bezeichnet. Die Wahrscheinlichkeit eines Attributwerts wird dabei als eine bedingte Wahrscheinlichkeit dargestellt, wobei als Bedingung die probabilistischen Konzepte genutzt werden. Diese Beschreibung wird im Verfahren weiterhin auch zur Bestimmung der Cluster genutzt. Das leitende Prinzip ist es dabei, Cluster zu erzeugen, deren Beschreibung die Vorhersage von möglichst vielen Informationen über bisher ungesehene Instanzen des Clusters erlaubt, im Sinne einer erwarteten Anzahl an korrekt vorhergesagten Attributwerten. Die genutzte Metrik wird dabei als Kategorie-Nützlichkeit bezeichnet. Das in COBWEB umgesetzte Verfahren zur konzeptuellen Clusteranalyse ist unüberwacht und inkrementell.

2.4.2 Ontologie-Lernen

Die vorgestellten Arten des maschinellen Konzeptlernens betreffen das Lernen symbolischer Konzeptdefinitionen aufgrund von symbolisch oder numerisch dargestellten Attributen. Als Konzepte werden dabei mathematisch dargestellte Hypothesen gelernt.

Eine ähnliche Fragestellung und auch darüber hinausgehende Aspekte werden strukturiert auch im Bereich des Ontologie-Lernens betrachtet. Hierbei ist es das Ziel, Definitionen und eine Axiomatisierung für die Konzepte und Relationen einer Ontologie zu erlernen, z. B. auf Basis von textuellen

¹ Englisch: conceptual clustering

Ressourcen. Beim Ontologie-Lernen erstellte Definitionen müssen im Vergleich zum klassischen Konzeptlernen in der Repräsentationssprache der Ontologie dargestellt werden, z. B. also in OWL. Das Lernen von Ontologien erfolgt in der Regel schichtenweise [Cim06]. Zuerst werden relevante Begriffe und ihre Synonyme bestimmt. Auf dieser Grundlage werden Konzepte definiert und diese anschließend taxonomisch angeordnet. Weiterhin werden Relationen definiert und ebenfalls taxonomisch angeordnet. Schließlich werden darauf aufbauend Axiome gelernt. Dieses schrittweise Vorgehen im Ontologie-Lernen besitzt dabei eine deutliche Ähnlichkeit zum Vorgehen beim manuellen Ontologie-Entwurf (vgl. 2.2.3). Ontologie-Lernen kann lexikalisch auf Basis textueller Ressourcen und unter Verwendung von Methoden zur Verarbeitung natürlicher Sprache, statistisch oder logisch erfolgen [Asi18]. Ein wichtiger Aspekt des lexikalischen Ontologie-Lernens ist, dass neben Konzeptdefinitionen auch konkrete Bedingungen an die Beziehungen¹ zwischen Konzepten als Axiome gelernt werden können [Völ09]. Das Erlernen von Ontologien erfolgt in der Regel semi-automatisch [Völ09] und unter einer manuellen Evaluation der gelernten Ontologien [Asi18].

Die Nutzung von textuellen Ressourcen beim Ontologie-Lernen geht über den Fokus der adaptiven Umweltmodellierung in dieser Arbeit hinaus, ermöglicht allerdings das Erlernen von semantischen und nicht aus Umgebungsbeobachtungen ableitbaren Informationen für ein Wissensmodell. Das Themengebiet des Ontologie-Lernens kann somit als komplementär zum in dieser Arbeit vorgestellten Ansatz für die adaptive Umweltmodellierung angesehen werden. Die Methoden des Ontologie-Lernens könnten z. B. genutzt werden, um aus Umgebungsbeobachtungen erlernte Konzepte um semantische Informationen zu erweitern. Als einen ersten Schritt in eine solche Richtung stellt Abschnitt 8.3.3 eine mögliche Erweiterung der adaptiven Umweltmodellierung durch Integration externen semantischen Wissens vor.

¹ Englisch: property restrictions

2.4.3 Kognitive Architekturen

Neben dem tatsächlichen Erlernen neuer Konzepte spielen in der adaptiven Umweltmodellierung auch Fragen eine Rolle, wie unter welchen Umständen und auf welche Art und Weise ein Wissensmodell erweitert und angepasst werden sollte. In Bezug auf solche Fragen können Denkanstöße in den Erkenntnissen der Kognitionswissenschaften zum menschlichen Konzeptlernen gefunden werden. Im Speziellen sind für diesen Zweck kognitive Architekturen relevant. Kognitive Architekturen stellen dabei implementierte und ausführbare Modelle der menschlichen Kognition dar, welche auf einer entsprechenden Kognitionstheorie beruhen [Bac03]. Kognitive Architekturen können in ihren Grundbegriffen auf abstrakte Weise auch zur objektorientierten Umweltmodellierung ähnlich sein. So besitzen z. B. manche kognitive Architekturen begrifflich auch ein Weltmodell. Da in dieser Arbeit die adaptive Umweltmodellierung im Mittelpunkt steht, soll an dieser Stelle nicht weiter auf grundsätzliche Ähnlichkeiten zur objektorientierten Umweltmodellierung eingegangen werden. Stattdessen sollen die für die adaptive Wissensverwaltung relevanten Aspekte in kognitiven Architekturen betrachtet werden. Dies betrifft z. B. Prinzipien, nach welchen sich die adaptive Umweltmodellierung in ihrem Vorgehen richten kann. Als ein Beispiel soll hier die MicroPsi Architektur [Bac03, Bac07] von Bach genannt werden. In dieser kognitiven Architektur werden beispielsweise Kategorien für Objekte durch die Verallgemeinerung von Objektrepräsentationen gewonnen. Die als Grundlage betrachteten Objekte müssen dabei alle hinreichend ähnlich sein. Informationen über beobachtete Objekte werden in einem Protokoll gespeichert. Die Inhalte dieses Protokollspeichers sind in regelmäßigen Abständen Gegenstand einer Weiterverarbeitung, welche in MicroPsi als Reflektion bezeichnet wird. Ziel dieser Reflektion ist es, die Inhalte des Protokollspeichers zu komprimieren, indem enthaltene Objekte durch ihre Kategorien ersetzt und dargestellt werden. Der Erwerb neuer komplexer Konzepte oder Kategorien erfolgt in MicroPsi nicht in einem Schritt, sondern betrachtet über das Protokoll immer eine Historie von Perzeptionsschritten.

Die Grundsätze und Prinzipien des genannten Vorgehens von kognitiven Architekturen können nun auf angepasste Weise auch in der adaptiven Umweltmodellierung Beachtung finden. Einige der in Kapitel 8 dargestellten Anteile der adaptiven Wissensverwaltung lassen sich somit über Denkanstöße aus der menschlichen Kognition motivieren und begründen.

2.4.4 Spezifische Ansätze

Von Daoutis [Dao12, Dao13] wird ein insgesamt ähnlicher Ansatz wie in der adaptiven Umweltmodellierung betrachtet. Dabei wird zunächst von einer ähnlichen Problemstellung wie der des objektorientierten Umweltmodells ausgegangen, für das Anwendungsgebiet der kognitiven Robotik. Im Mittelpunkt der Arbeit steht die Verankerung¹ von Sensordaten bzgl. wahrgenommener physischer Objekte in semantischen Konzepten [Dao13]. Diese Konzepte dienen dabei ähnlich wie in der objektorientierten Umweltmodellierung zu einer Vervollständigung von wahrgenommenen Objekten hinsichtlich ihrer Bedeutung. Als Wissensbasis für Alltagswissen sowie Top-Level Ontologie wird dabei Cyc eingesetzt. Über die Ähnlichkeiten zum objektorientierten Umweltmodell hinaus wird ebenfalls betrachtet, dass Roboter in einer offenen Umgebung operieren und hier auch Domänenwissen dynamisch erwerben müssen. Dabei werden neue Definitionen für Konzepte in Form von merkmalsbasierten visuellen Beschreibungen gelernt. Dieses Vorgehen wird als konzeptuelle Verankerung bezeichnet. Der in [Dao12] beschriebene Ansatz ist dabei in der Lage, für eine begriffliche Beschreibung eines Konzepts entsprechende visuelle Merkmale unter Verwendung von Internetressourcen zu erwerben. Diese Merkmale dienen dann zusammen mit dem Begriff als neue Konzeptdefinition und konzeptueller Anker. Die Merkmale werden dabei aus Trainingsdaten extrahiert, welche mittels Suche im Internet bzgl. des gegebenen Begriffs erworben und anschließend vorverarbeitet werden, um z. B. Falschresultate der Suche zu erkennen. Zur

¹ Im Sinne von Perceptual Anchoring

Extraktion der Merkmale werden anschließend Methoden des maschinellen Sehens eingesetzt. Um gelernte Konzeptbeschreibungen im existierenden Hintergrundwissen Cyc zu integrieren und hierarchisch einzuordnen, werden ebenfalls web-basierte Informationen genutzt, welche Begriffe auf Identifikatoren der Cyc Top-Level Ontologie abbilden.

Ein weiterer Ansatz zum Erlernen von Erfahrungswissen für handlungsbezogene Konzepte wird von Tenorth und Beetz [Ten09] für KnowRob (vgl. Abschnitt 2.3.1) vorgestellt. Hierbei wird ein humanoider Roboter betrachtet, welcher in einer Umgebung aufgabenbezogene Handlungen vollführt und deren Parameter protokolliert. Dieses Protokoll dient als Datenbasis, um neue handlungsbezogene Konzepte als Unterklassen existierender Konzepte ableiten zu können. Dazu müssen im beschriebenen Ansatz einerseits die Parameter spezifiziert werden, welche als Beobachtungsdaten in das neue Konzept einfließen sollen, und andererseits das Konzept, welches durch eine neue Unterklasse spezialisiert werden soll. Als Beispiel wird in [Ten09] der Ort genannt, an welchem sich ein Roboter befinden sollte, um bestimmte Aufgaben effektiv und effizient erledigen zu können, wie z. B. das Aufnehmen von Objekten eines bestimmten Typs. Ein solcher Ort stellt dabei eine aufgaben- sowie objekttyp-spezifische Unterklasse eines Konzepts Manipulationsort dar, welche im Ansatz formal in OWL beschrieben wird. Zum Erlernen dieses Konzepts werden die im Protokoll gespeicherten historischen Daten verwendet. Positionsdaten werden dabei zunächst geclustert und mit einem Namen symbolisch beschrieben. Anschließend wird für diese und für die vorgegebenen Typen von ebenfalls symbolischen Beobachtungsdaten ein Entscheidungsbaum für das Zielkonzept trainiert. Die Regeln dieses Entscheidungsbaums werden schließlich in OWL Beschreibungen zur Definition der neuen Unterklasse transformiert. Von Tenorth et al. wird in [Ten11] ebenfalls ein Ansatz genannt (vgl. Abschnitt 2.3.1), wie zu einem gegebenen Begriff neue visuelle Objektmodelle unter Verwendung von Internetressourcen semi-automatisch erworben werden können. Dieser Ansatz ist in seinem Resultat sehr ähnlich zum zuvor vorgestellten Ansatz von Daoutis [Dao12].

2.4.5 Zusammenfassung

In diesem Abschnitt wurde relevante Literatur mit Bezug auf die adaptive Umweltmodellierung für offene Welten vorgestellt. Da diese eine spezifische Problemstellung innerhalb der objektorientierten Umweltmodellierung ist, wurde Literatur aus unterschiedlichen relevanten Bereichen mit Bezug zu Teilaufgaben der adaptiven Umweltmodellierung jeweils im Überblick vorgestellt. Dies betraf u. a. das Erlernen von Konzepten aus Beispieldaten, das Erlernen komplexer semantischer Modelle für Ontologien sowie relevante Prinzipien aus dem Bereich des menschlichen Konzeptlernens. Weiterhin wurden Arbeiten vorgestellt, die eine ähnliche Zielsetzung wie die adaptive Umweltmodellierung verfolgen.

Für die Thematik des Konzeptlernens beschreibt die konzeptuelle Clusteranalyse dabei ein grundsätzlich relevantes und ähnliches Vorgehen. In der adaptiven Umweltmodellierung muss allerdings zusätzlich die probabilistische Informationsrepräsentation von Attributwerten beachtet werden. Auch können taxonomische Wissensstrukturen in der objektorientierten Umweltmodellierung nicht rein auf Basis von beobachteten Merkmalen erzeugt werden. Hier müssen auch ontologische Prinzipien beachtet werden. Der Bereich des Ontologie-Lernens betrifft hauptsächlich zur adaptiven Umweltmodellierung komplementäre semantische Aspekte und kann ergänzend zu dieser genutzt werden. Aus dem Bereich der kognitiven Architekturen lassen sich wertvolle Denkanstöße bzgl. Prinzipien der menschlichen Kognition ableiten, welche auch für die adaptive Umweltmodellierung Relevanz besitzen. Mit [Dao12] ist weiterhin ein Ansatz gegeben, welcher in Teilen eine ähnliche Problemstellung wie die der adaptiven Umweltmodellierung betrachtet, allerdings unter anderen Voraussetzungen. Als ein Treiber für das Erlernen neuer Konzeptdefinitionen dient hier die begriffliche Beschreibung eines Konzepts, wohingegen in der adaptiven Umweltmodellierung probabilistisch beschriebene Entitätsbeobachtungen als Treiber und Datenbasis des Lernens dienen. Der Ansatz in [Ten09] beschreibt weiterhin eine Möglichkeit, auf Basis bisheriger Handlungen neues Erfahrungswissen zu erzeugen.

2.5 Informationsdarstellung beim maschinellen Sehen

Das Themengebiet des maschinellen Sehens hat eine querschnittliche Relevanz für die objektorientierte Umweltmodellierung und wird daher in einem eigenen Abschnitt behandelt. Das maschinelle Sehen beschäftigt sich mit der Erkennung von Objekten in z. B. Bild-, Video- oder 3D-Tiefendaten, welche über visuelle Sensoren aufgenommen werden. Der betrachtete Frequenzbereich dieser Sensoren muss dabei nicht notwendigerweise auf den für Menschen sichtbaren Spektralbereich begrenzt sein. Die Erkennung von Objekten lässt sich unterteilen in die Teilaufgaben der Detektion, Identifikation und Klassifikation von Objekten in Sensordaten. Ziel der Detektion ist es, diejenigen Datenanteile zu bestimmen, durch welche Objekte repräsentiert werden. Dies beinhaltet auch eine Lokalisierung der detektierten Objekte innerhalb des Referenzsystems der Sensordaten (z. B. in Form von Pixelkoordinaten). Die Identifizierung beschäftigt sich mit der Wiedererkennung von detektierten Objekten auf Basis von Objektmodellen. Diese Objektmodelle können entweder a priori modelliert werden oder erst zur Laufzeit erworben bzw. gelernt werden. Die Klassifikation hat zum Ziel, detektierte Objekte bekannten Klassen zuzuordnen. Diese Objektklassen werden ebenfalls über Modelle beschrieben, welche häufig a priori auf Grundlage von Trainingsdaten eingelernt werden.

Das Themengebiet des maschinellen Sehens besitzt Überschneidungen mit anderen relevanten Themengebieten der Umweltmodellierung. Betroffen sind dabei z. B. die Gebiete der Wissensrepräsentation und des Konzeptlernens. Mit der Wissensrepräsentation bestehen Überschneidungen in der Art und Weise, wie Modelle von zu erkennenden Objekten bzw. Objektklassen dargestellt werden. Beim Konzeptlernen ist die Art und Weise betroffen, wie solche Modelle gelernt oder eintrainiert werden. Auf diese beiden Aspekte wird in den Abschnitten 2.5.1 und 2.5.2 detaillierter eingegangen.

Weiterhin besitzt das maschinelle Sehen auch direkte Überschneidungen mit der objektorientierten Umweltmodellierung, was die betrachteten Aufgaben angeht. So müssen z. B. auch in Umweltmodellen Objekte im Sinne einer

Identifikation wiedererkannt werden. In der objektorientierten Umweltmodellierung werden zu diesem Zweck Verfahren zur Datenassoziation eingesetzt. Auch die Klassifikation detektierter Objekte besitzt eine entsprechende Aufgabe in der Umweltmodellierung. Dies ist die Zuordnung der Repräsentanten in der Weltmodell-Komponente zu den Konzepten im Hintergrundwissen. Zu diesem Zweck werden in der objektorientierten Umweltmodellierung probabilistische Klassifikationsverfahren eingesetzt. Weiterhin ist das Erlernen von Modellen für neue Objektklassen relevant für die adaptive Umweltmodellierung. Die adaptive Umweltmodellierung lernt ebenfalls neue Klassen für als Repräsentanten im Weltmodell dargestellte Objekte unter Anwendung probabilistischer Fusionsverfahren.

2.5.1 Darstellung von Objektmodellen

Im Bereich des maschinellen Sehens ist das Hauptanliegen die Erkennung von Objekten in Bildern und Videosequenzen. Die meisten Ansätze erfordern zu diesem Zweck keine Zustandsrepräsentation. Eine Ausnahme sind Verfahren, welche zur Unterstützung der Objekterkennung in Videosequenzen eine Verfolgung¹ dieser Objekte durchführen und dazu Objektpositionen als Zustand vorhalten. Relevant für die Darstellung von Informationen im Bereich des maschinellen Sehens sind die eingesetzten Modelle zur Repräsentation von Objekten und Objektklassen.

Überblick zu Objektrepräsentationen

Mit dem Fortschreiten der Forschung haben sich unterschiedlich detaillierte Formen der Objektmodellierung ergeben. Einfache geometriebasierte Ansätze modellieren Objekte beispielsweise mittels Kanten, Flächen und Ecken bzw. in Form einfacher geometrischer Primitive wie Würfeln, Quadern oder Kugeln. Darauf aufbauend wurden komplexere Modelle entwickelt, welche

¹ Englisch: tracking

von ansichtsbasierten Modellen über teilebasierte Modelle bis hin zu merkmalsbasierten und hierarchischen Modellen reichen.

Ansichtsbasierte Ansätze Ansichtsbasierte Ansätze werden häufig zur Identifizierung von Objekten eingesetzt. Die Ansätze nutzen vollständige Ansichten von Objekten in Bildern als Objektmodelle. Für bekannte Objekte werden dabei Datenbanken mit einer Vielzahl von Ansichten pro Objekt erstellt, gegen welche ein zu identifizierendes Objekt abgeglichen wird. Dieser Abgleich kann direkt auf den Bildinformationen stattfinden. Alternativ können zur Effizienzsteigerung auf Basis der Ansichten noch Merkmale berechnet werden (z. B. [Mur95]), welche dann zur Identifizierung genutzt werden. Unter Verwendung lokaler Merkmale kann weiterhin, gegeben eine ausreichend große Menge an unterschiedlichen Objektansichten, ein dreidimensionales Modell des Objekts erzeugt werden (z. B. [Gor06, Col09]). Die lokalen Merkmale werden dabei dazu genutzt, um verschiedene Ansichten des Objektes für eine automatisierte Modellerzeugung zueinander in Beziehung zu setzen.

Teilebasierte Ansätze Teilebasierte Ansätze (z. B. [Fel00, Fel10, Zha14]) beschreiben Objekte als Summe ihrer unterscheidbaren Teile und deren relativer Positionen zueinander. Zwischen den Objektteilen bestehen dabei elastische Verbindungen, so dass eine deformierbare Konfiguration der Teile ermöglicht wird [Fis73]. Die einzelnen zu erkennenden Objektteile selbst können durch unterschiedliche Modelle repräsentiert werden, z. B. über ihre visuelle Erscheinung [Fel00]. Teilebasierte Ansätze besitzen dabei eine Ähnlichkeit zu semantischen Modellen, in welchen ebenfalls mittels Teile-Ganzes-Beziehungen die Objektteile modelliert werden. Diese beiden Arten von Teilemodellen lassen sich auch zu einem integrierten Modell kombinieren [Lim11].

Merkmalsbasierte Ansätze Merkmalsbasierte Ansätze nutzen Mengen lokaler, subsymbolischer Merkmale zur Beschreibung von Objekten. Lokale Merkmale beschreiben für Bilddaten dabei beispielsweise die Bildwerte in einer nahen Umgebung um ein betrachtetes Pixel auf eine zusammenfassende Weise. Derartige Merkmale korrespondieren im Allgemeinen nicht

mit den für Menschen intuitiven erscheinungsbezogenen Objekteigenschaften (wie Farbe oder Form) und sind somit subsymbolisch. Ein Objektmodell stellt dann die einzelnen lokalen Merkmale eines Objekts in Form von Deskriptoren dar. Dabei können auch die relativen Positionen solcher Merkmale zueinander repräsentiert werden. Einen vielbeachteten Ansatz für lokale Merkmale stellt die von Lowe [Low04] eingeführte skaleninvariante Merkmalstransformation (SIFT¹, [Low99]) dar. Diese ermöglicht die Bestimmung von rotations- und skalierungsinvarianten Merkmalen für Schlüsselpunkte eines Objektbildes. Zur Modellierung von Objekten (z. B. für eine Identifikation) werden zunächst deren lokale Merkmale erfasst. Zu jedem Merkmal wird dann ein charakteristischer Deskriptor erstellt und samt der relativen Position des Merkmals in einer Datenbank gespeichert [Low04]. Eine weitere wichtige Art von lokalen Merkmalen stellen die von Dalal eingeführten Histogramme über Kantenrichtungen (HOG², [Dal05]) dar. Diese Histogramme werden für einzelne Regionen eines Bildes berechnet. Sie beschreiben, wie die Orientierung der in einer Region detektierten Kanten verteilt ist.

Künstliche neuronale Netze Den aktuellen Stand von Technik und Wissenschaft über alle Teilaufgaben der Objekterkennung stellen künstliche neuronale Netze dar. Die nachfolgend betrachteten vorwärtsgerichteten neuronalen Netze bestehen dabei aus untereinander verbundenen Schichten von Neuronen. Eine Eingabeschicht ist für die Entgegennahme der zu verarbeitenden Daten (z. B. ein Bild) zuständig. Die Ergebnisse der Verarbeitung (z. B. die Klassifikation der Objekte im Bild) werden von einer Ausgabeschicht dargestellt. Verbunden werden Ein- und Ausgabeschicht über sog. versteckte Schichten. Die Verbindungen zwischen den Neuronen der unterschiedlichen Schichten können über Gewichte parametrisiert werden. Die Gewichte stellen dabei die wesentlichen Parameter von trainierten Modellen dar. Ein für das maschinelle Sehen besonders wichtiger Typ von vorwärtsgerichteten neuronalen Netzen ist durch die faltenden neuronalen Netze (CNNs³) von LeCun [LeC98] gegeben. Faltende neuronale Netze

¹ Englisch: scale-invariant feature transform

² Englisch: histogram of oriented gradients

³ Englisch: convolutional neural networks

orientieren sich in ihrem Aufbau an Prinzipien, welche von der Physiologie des menschlichen Sehens inspiriert sind. Speziell zusammen mit modernen tiefen Architekturen (sog. „Deep Learning“) sind faltende neuronale Netze sehr erfolgreich im Bereich der Objektdetektion und -klassifikation (vgl. z. B. [Gir14, Sze14, Gir15, Ren15, He16, Red17]).

Neuronale Netze besitzen gegenüber anderen Ansätzen der Objekterkennung einen wichtigen Unterschied. Dies betrifft die Art und Weise, wie die zur Erkennung verwendeten Merkmale ausgewählt werden. Werden diese Merkmale bei anderen Ansätze oft a priori manuell erstellt und ausgewählt, so erlernen neuronale Netze ihre Merkmale selbsttätig in ihrer Trainingsphase. Diese Tatsache ist auch für die Informationsdarstellung in neuronalen Netzen relevant. In vorwärtsgerichteten neuronalen Netzen ergeben sich die Modelle für Objektklassen in Form einer hierarchischen, verteilten Darstellung. Ein Modell zur Repräsentation einer bestimmten Objektklasse liegt dabei verteilt innerhalb des neuronalen Netzes vor. Es wird durch die unterschiedlichen Gewichte der Verbindungen zwischen den Schichten repräsentiert. Eine Objektklasse wird durch die geschichtete Architektur somit auf unterschiedlichen Abstraktionsniveaus repräsentiert. Die unteren, eingabenahe Schichten eines Netzes stellen dabei oft subsymbolische Merkmale dar. Diese werden auf darüber liegenden Schichten zu immer komplexeren Merkmalen (für Bilddaten können dies z. B. Kanten, Linienzüge, Teilkonturen usw. sein) zusammengesetzt. Manchen dieser komplexeren Merkmale kann dabei eine begriffliche Bedeutung zugeordnet werden. Die Darstellung von Objektmodellen erfolgt weiterhin geteilt in dem Sinne, dass sich die Repräsentationen verschiedener Objektklassen die Merkmale der unteren Schichten eines Netzes teilen [LeC15]. Erst auf den darüber liegenden Schichten werden diese Merkmale dann unterschiedlich kombiniert zur Unterscheidung der Objektklassen.

Attributbasierte Objektrepräsentation

Im Bereich der Umweltmodellierung, vor allem für die Zustandsrepräsentation, ist die Darstellung von Objekten mittels semantisch interpretierbaren,

d. h. für einen Menschen verständlichen Attributen wichtig. Auch für die Objekterkennung, vor allem im Bereich der Servicerobotik, gewinnt dieser Ansatz aufgrund seiner Möglichkeiten zunehmend an Bedeutung [Sun13, Bal15]. Beispiele für attributbasierte Objektrepräsentationen sind die grundlegenden Ansätze von Farhadi [Far09] und Lampert [Lam09], der Ansatz zur Objektidentifikation durch visuelle Attribute und sprachliche Begriffe von Sun [Sun13] sowie die Repräsentation mittels relativer Attribute von Parikh [Par11].

Vorteile der attributbasierten Objektrepräsentation Die attributbasierten Ansätze zur Objektrepräsentation bieten einige Vorteile. Zunächst ermöglichen sie es, Objekte und Objektklassen durch relativ einfache Modelle zu beschreiben, beispielsweise als Liste aus charakteristischen Attributen. Diese Attribute sind in vielen Ansätzen semantisch interpretierbar (z. B. die Farbe oder Form von Objekten [Lam09, Sun13]), was eine enge Kopplung mit sprachlichen Beschreibungen von Objekten ermöglicht. Der Ansatz von Farhadi [Far09] erlaubt es beispielsweise, die aus Bildmaterial über Objekte gewonnenen Informationen sprachlich wiederzugeben. Weiterhin ist es möglich, für klassifizierte Objekte ungewöhnliche Objekteigenschaften aufzuzählen, welche im Bildmaterial entdeckt wurden. Auch die Verwendung relativer Attribute im Ansatz von Parikh [Par11], bei welchem Attributwerte als Vergleich zu Eigenschaften bekannter Objekte dargestellt werden, erlaubt es, eine vergleichende sprachliche Beschreibung für unbekannte Objekte zu erzeugen. Die allgemeine Möglichkeit, detaillierte Informationen über betrachtete Objekte auf einer semantischen Ebene bereitstellen zu können, ist auch in Bezug auf eine natürlichsprachliche Kommunikation mit den Nutzern eines kognitiven Systems von Vorteil [Bal15].

Attribute als Zwischenschicht der Objektrepräsentation

Begründet liegen die vielfachen neuen Möglichkeiten attributbasierter Ansätze in der Tatsache, dass durch die Beschreibung von Objekten mittels

Attributen eine neue Zwischenschicht der Informationsrepräsentation zwischen Merkmalen auf der einen Seite und Symbolen für Objekt- bzw. Klassennamen auf der anderen Seite eingebracht wird. Dies bedeutet einerseits, dass sowohl Objekte als auch Objektklassen nun auf Basis der definierten Attribute modelliert werden können, was die bereits angesprochene Vereinfachung ihrer Modellierung aufgrund der Abstraktion von Merkmalen ermöglicht. Oft ist eine Liste von Attributen als Objektmodell ausreichend. Die einzelnen Attribute werden dabei häufig für die weitere Verarbeitung als stochastisch unabhängig angenommen (z. B. [Lam09, Sun13]), gegeben bildhafte Evidenz. Andererseits müssen nun die Attribute ihrerseits auf Basis von Objektmerkmalen definiert werden, um ihre Fundierung z. B. in Bildinformationen zu erreichen. Eine besondere Schwierigkeit im Vergleich zu ansichts- oder merkmalsbasierten Ansätzen ist dabei das Problem, dass Attribute unabhängig von den betrachteten Objektklassen definiert werden sollten. Dies erhöht die Nützlichkeit der einzelnen Attribute und reduziert wesentlich den Aufwand, der zur Definition oder zum Training der Modelle notwendig ist.

Geläufige Attribute und zugrunde liegende Merkmale

Als Attribute zur Beschreibung einzelner Objekte sowie von Objektklassen nutzen die attributbasierten Ansätze Eigenschaften wie die Farbe, Form, Größe, Textur oder das Material zu beschreibender Objekte (z. B. [Far09, Lam09, Sun13]). Weiterhin beziehen sie das Vorhandensein von charakteristischen Objektteilen mit ein. Zur Bestimmung dieser Attribute können ansichtsbasierte Verfahren auf Bildregionen oder lokale Merkmale genutzt werden, z. B. in Verbindung mit Bildpyramiden, sowie geometrische Merkmale. Als Ausgangsdaten werden Farbbilder und RGB-D Daten verwendet, welche Farbbilder pro Pixel mit zusätzlichen Tiefeninformationen anreichern.

2.5.2 Lernen von Modellen für Objektklassen

In Bezug auf das Konzeptlernen in der adaptiven Umweltmodellierung ist auch das Erlernen neuer Objektklassen beim maschinellen Sehen ein relevantes Thema. Dabei sind hauptsächlich Ansätze betroffen, die eine Klassifikation von Objekten ermöglichen. Viele dieser Verfahren dienen zugleich auch der Detektion von Objekten. Für die Objektidentifikation werden dagegen Modelle konkreter Objekte genutzt, nicht allgemeiner Klassen, daher sind entsprechende Ansätze an dieser Stelle weniger relevant.

Merkmalsbasierte Ansätze Viele der zuvor genannten Ansätze erlernen Modelle für Objektklassen a priori zur Entwurfszeit eines Systems. Zur Laufzeit werden die Verfahren dann nur zur Vorhersage der Klasse von betrachteten Objekten genutzt. Das Training kann dabei stufenweise erfolgen. Sind die zu verwendenden Merkmale vorgegeben, so können Werte für diese Merkmale aus Trainingsdaten (z. B. Bildern) extrahiert und zu Deskriptoren zusammengefasst werden. Auf solchen Deskriptoren können dann Klassifikationsverfahren trainiert werden. Diese Klassifikationsverfahren lernen dabei beispielsweise die Objekte einer Klasse von den Objekten der restlichen betrachteten Klassen zu unterscheiden. Die gelernten Parameter der Klassifikationsverfahren stellen hier das Modell der Objektklasse dar. Zusätzlich können die extrahierten Merkmale zunächst vorverarbeitet werden. Zu diesem Zweck kann eine Ballungsanalyse¹ erfolgen, welche die Merkmale zu Gruppen zusammenfasst. Eine derartige Zusammenfassung kann die Generalisierungsfähigkeit des nachgelagerten Klassifikationsverfahrens erhöhen. Weiterhin kann als Vorverarbeitung eine Merkmalsselektion erfolgen. Auf diese Weise ist es möglich, nur die aussagekräftigsten Merkmale zum Training eines Klassifikationsverfahrens zu verwenden. Dies kann zu einer Verbesserung der Erkennungsleistung führen. Je nach Komplexität des Modells und der Menge der verfügbaren Trainingsdaten kann ein Lernvorgang zeitintensiv sein. Die Komplexität eines zu lernenden Modells, gemessen z. B. über die Anzahl der festzulegenden Parameter, bestimmt

¹ Englisch: clustering

weiterhin die Menge an Trainingsdaten, die benötigt wird, um ein Modell mit einer gewünschten Erkennungsleistung trainieren zu können.

Das Training der Modelle von neuronalen Netzen erfolgt in einem ganzheitlichen Ansatz. Dabei wird nicht nur das Klassifikationsverfahren für gegebene Objektklassen trainiert, sondern zugleich auch die zu verwendenden Merkmale. Dies ist in der hierarchischen Repräsentation neuronaler Netze begründet. Auf diese Weise erhöht sich im Vergleich zu anderen Ansätzen die Anzahl der festzulegenden Parameter und somit die Komplexität der zu erlernenden Modelle. Dies bedingt eine ebenfalls erhöhte Anzahl an Trainingsdaten sowie einen erhöhten Zeitaufwand zur Durchführung des Trainings. Für komplexere Modelle können dabei Millionen von Trainingsdaten benötigt werden [He16]. Auch die Trainingszeit für neuronale Netze kann, abhängig von der verfügbaren Hardware und Rechenleistung, Tage oder sogar Wochen betragen [Sze14]. Eine adaptive Anpassung an neue Objektklassen zur Laufzeit eines Systems ist für merkmalsbasierte Ansätze im Allgemeinen nicht vorgesehen. Allerdings kann durch Konzepte wie Transferlernen und unter Ausnutzung der Tatsache, dass in neuronalen Netzen die unteren Schichten oftmals objektunabhängige Merkmale darstellen, eine Reduktion der benötigten Trainingszeit und -daten erreicht werden.

Attributbasierte Ansätze Sowohl von Farhadi [Far09] als auch von Lampert [Lam09] wird die Möglichkeit beschrieben, Modelle für neue Objektklassen im Fall einer attributbasierten Objektrepräsentation rein auf der Grundlage von natürlichsprachlichen Beschreibungen zu erlernen. Dieses Vorgehen wird möglich, wenn die zur Beschreibung von Objekten verwendeten Attribute einerseits unabhängig von einzelnen Objektklassen definiert sind und somit einen Transfer gelernten Wissens auf neue Klassen ermöglichen, und andererseits mit natürlichsprachlichen beschreibbaren Objekteigenschaften korrespondieren. Auch bei der Objektrepräsentation durch relative Attribute von Parikh [Par11] ist es möglich, unbekannte Objektklassen aufgrund einer vergleichenden Beschreibung der Attribute der Objektklasse gegenüber den Attributen bekannter Objektklassen zu erlernen. Weiterhin wird gezeigt, dass eine attributbasierte Objektrepräsentation auch beim Erlernen von Modellen für neue Objektklassen aus

Trainingsbildern vorteilhaft ist – hier wird eine Reduktion der Trainingsdaten ermöglicht.

2.5.3 Zusammenfassung zum maschinellen Sehen

Das Themengebiet des maschinellen Sehens ist aufgrund unterschiedlicher Aspekte relevant für die objektorientierte Umweltmodellierung. Zunächst können Verfahren des maschinellen Sehens zur vorgelagerten Sensordatenverarbeitung in der Umweltmodellierung eingesetzt werden. Dazu können Objekte in Bildern detektiert werden und für diese Objekte die Werte gewünschter Attribute bestimmt werden. Das Ergebnis dieser Verarbeitung kann dann an das objektorientierte Umweltmodell übergeben werden. Hierbei sind nach den Prinzipien der objektorientierten Umweltmodellierung vor allem attributbasierte Verfahren des maschinellen Sehens von Interesse.

Weiterhin werden beim maschinellen Sehen Aufgaben gelöst, die grundsätzlich auch in der objektorientierten Umweltmodellierung anfallen, wenn auch in abgewandelter Form. Dies betrifft die Identifikation von beobachteten Objekten sowie deren Klassifikation. Verfahren des maschinellen Sehens, vor allem tiefe neuronale Netze, stellen dabei den Stand von Wissenschaft und Technik für diese Aufgaben dar. In der objektorientierten Umweltmodellierung steht die sensorische Erfassung von Objekten allerdings nicht im Vordergrund. Der zentrale Aspekt der Umweltmodellierung ist die schritthaltende semantische Repräsentation eines Umgebungszustandes. Diese dient als Ausgangsbasis für Entscheidungen und zur Planung von z. B. Handlungen in autonomen kognitiven Systemen. Erkannte Objekte stellen hierbei die notwendigen Eingabedaten dar.

Für die adaptive Umweltmodellierung sind Verfahren des maschinellen Sehens interessant, welche zur Laufzeit eines Systems neue Modelle für Objektklassen erlernen können. In diesem Bereich sind vor allem wieder attributbasierte Verfahren relevant. Die Verwendung von Attributen als eine Zwischenschicht zur Informationsrepräsentation ermöglicht es dabei, neue Objektklassen mit einer deutlich reduzierten Menge von Trainingsdaten zu erwerben. Für die adaptive Umweltmodellierung liegt ebenfalls eine solche

Aufgabenstellung vor, bei welcher zur Laufzeit eines Systems auf Basis einer relativ geringen Menge von Trainingsdaten neue Konzepte gelernt werden sollen. Die datenintensiven Verfahren des maschinellen Sehens, wie tiefe neuronale Netze, sind an dieser Stelle weniger geeignet.

2.6 Zusammenfassung

In diesem Kapitel wurde die für diese Arbeit relevante Literatur vorgestellt. Aufgrund der querschnittlichen Natur der betrachteten Thematik wurde dabei der Stand der Wissenschaft und Technik in unterschiedlichen Themengebieten betrachtet und im Überblick sowie mit Bezug zur adaptiven Umweltmodellierung dargestellt. Als grundlegende Themengebiete waren die Wissensmodellierung und -repräsentation, die probabilistische Informationsverarbeitung sowie das Konzeptlernen betroffen. Aufgrund der Unterschiedlichkeit dieser Themengebiete wurden diese jeweils individuell zusammengefasst und in ihrer Relevanz für diese Arbeit bewertet. Daher wird an dieser Stelle auf eine weitergehende Zusammenfassung verzichtet.

3 Adaptive Umweltmodellierung

In dieser Arbeit wird eine adaptive Umweltmodellierung für kognitive Systeme als Erweiterung der objektorientierten Umweltmodellierung betrachtet. Dieses Kapitel gibt einen Überblick über die adaptive Umweltmodellierung und stellt zugleich dar, wie sich die nachfolgenden Kapitel in den Ansatz der adaptiven Umweltmodellierung einfügen. Weiterhin werden allgemeine Grundlagen der objektorientierten Umweltmodellierung eingeführt. Spezifische Aspekte der Umweltmodellierung werden je nach Bedarf direkt in den späteren Kapiteln dargestellt.

3.1 Grundlagen der Umweltmodellierung

Das objektorientierte Umweltmodell stellt die Ausgangsbasis für diese Arbeit dar, auf welcher die adaptive Umweltmodellierung aufbaut. In der Umweltmodellierung wird die von einem technisch kognitiven System beobachtete Umgebung repräsentiert. Als Umgebung wird dabei ein raumzeitlicher Ausschnitt einer gegebenen Anwendungsdomäne auf einem festgelegten Abstraktionsniveau betrachtet [Bel12c]. In diesem raumzeitlichen Ausschnitt werden mittels Sensoren Entitäten beobachtet. Häufig entsprechen diese Entitäten anfassbaren Objekten. Es können allerdings auch Abstrakta betroffen sein, wie z. B. Ereignisse oder Situationen einer Anwendungsdomäne.

Durch Umweltmodellierung wird eine abstrakte Repräsentation der betrachteten Umgebung erzeugt, z. B. in Form eines Modells [Kuw10]. Ein Modell stellt einen Sachverhalt auf eine vereinfachte, aber strukturierte Weise dar. Auch die Umweltmodellierung hat zum Ziel, die beobachtete Umgebung und

ihren Zustand abstrahiert zu erfassen und durch Verbindung mit einem semantischen Wissensmodell strukturiert darzustellen. Zu diesem Zweck wird das objektorientierte Umweltmodell eingesetzt. Dieses wurde ursprünglich von Beyerer [Bey07] vorgeschlagen und zusammen von Gheeta, Heizmann, Bauer, Belkin und Emter ([Emt08, Ghe08, Bau09, Hei10, Ghe10b]) weiter ausgearbeitet und umgesetzt. Das objektorientierte Umweltmodell besteht, wie bereits in Abbildung 1.1 dargestellt, aus zwei Anteilen: einer Weltmodell-Komponente und einem Hintergrundwissensmodell.

In der Weltmodell-Komponente erfolgt die schritthaltende Repräsentation des beobachteten Umgebungszustandes. Für jede in der Umgebung beobachtete Entität wird dabei ein sog. Repräsentant im Weltmodell angelegt [Bel12c]. Die für Entitäten beobachteten Eigenschaften und Merkmale werden als Attribute der Repräsentanten dargestellt und probabilistisch über Wahrscheinlichkeitsverteilungen beschrieben. Die einzelnen Attribute der Repräsentanten werden dabei als stochastisch unabhängig angenommen [Bau09]. Um ebenfalls die Beziehungen, welche zwischen repräsentierten Entitäten in der Umgebung bestehen, modellieren zu können, können auch Repräsentanten untereinander über Relationen verknüpft werden. Die im Weltmodell erfassten Informationen werden schritthaltend mit Umgebungsbeobachtungen aktualisiert. Dabei unterliegen sie einer probabilistischen Informationsverwaltung und -verarbeitung. Der aktuelle, im Weltmodell repräsentierte Umgebungszustand spielt auch für die adaptive Umweltmodellierung eine wichtige Rolle, z. B. in Bezug auf die Bewertung der Eignung eines Hintergrundwissensmodells. Kapitel 5 dieser Arbeit geht daher auf die Informationsverwaltung im objektorientierten Umweltmodell ein.

Die Strukturierung der erworbenen Informationen erfolgt unter Verwendung eines semantischen Hintergrundwissensmodells. Begrifflich werden in dieser Arbeit Informationen von Wissen unterschieden, jedoch ohne eine allzu scharfe Abgrenzung zwischen den beiden Begriffen zu definieren. Informationen stellen dabei interpretierte und ggf. verknüpfte Sensordaten dar [Das08], wie sie z. B. im Weltmodell abgelegt und fusioniert werden. Ein Wissensmodell beinhaltet in dieser Arbeit dagegen höherwertige, konsolidierte,

verknüpfte, ggf. nicht direkt beobachtbare und formal beschriebene Sachverhalte in Bezug auf eine betrachtete Anwendungsdomäne. Solches Wissen ist in der Umweltmodellierung als Vorwissen gegeben, welches bereits zur Entwurfszeit eines kognitiven Systems z. B. von Domänenexperten ausgewählt, aufbereitet und formal modelliert wird. Ein Hintergrundwissensmodell stellt solches Vorwissen formal und in einer für das objektorientierte Umweltmodell verarbeitbaren Form dar.

Das in einem Hintergrundwissensmodell gegebene Vorwissen wird in der objektorientierten Umweltmodellierung verwendet, um die beobachteten Informationen im Weltmodell ergänzen, verknüpfen und vervollständigen zu können. Dabei wird auch die Semantik von relevanten Typen von Objekten im Hintergrundwissen dargestellt. So kann z. B. die aufgabenbezogene Bedeutung oder der Zweck einer Entität im Hintergrundwissen modelliert sein und dem kognitiven System bei Bedarf genannt werden. Auch Informationen, welche nicht durch Umgebungsbeobachtungen erwerbbar sind, können im Hintergrundwissensmodell abgelegt werden und zur Vervollständigung der Repräsentanten des Weltmodells genutzt werden.

Entitäten bzw. genauer Typen von Entitäten werden im Hintergrundwissensmodell dabei über sog. Konzepte modelliert. Ein Konzept wird, analog zu Repräsentanten, ebenfalls durch Attribute beschrieben, deren Werte probabilistisch mittels Wahrscheinlichkeitsverteilungen dargestellt sind.

3.2 Adaptive Umweltmodellierung

Das Hintergrundwissen eines objektorientierten Umweltmodells wird zur Entwurfszeit eines kognitiven Systems von menschlichen Domänenexperten a priori festgelegt. Ein Hintergrundwissensmodell beschreibt somit alle Entitäten, die zur Entwurfszeit als relevant für den Betrieb eines kognitiven Systems betrachtet wurden.

Dabei kann aber immer nur ein abgeschlossener Teil der Anwendungsdomäne repräsentiert werden. Es gibt Anwendungsfälle, in welchen ein solch

abgeschlossenes Hintergrundwissensmodell ausreichend ist. Viele relevante Anwendungsdomänen von technisch kognitiven Systemen besitzen allerdings eine inhärente Komplexität, die eine vollständige manuelle Modellierung einer Domäne schwierig und sehr zeitaufwendig macht. In solchen Fällen muss in der Umweltmodellierung davon ausgegangen werden, dass ein Hintergrundwissensmodell per se eine Approximation darstellt und potentiell unvollständig ist. In realistischen Anwendungsdomänen kann z. B. bereits für begrenzte Anwendungsfälle die Anzahl der zu modellierenden Entitätstypen schnell sehr groß werden. Zusätzlich zeichnen sich Anwendungsfälle, in welchen menschliche Interaktion gegeben ist, oftmals durch eine hohe Dynamik aus. Diese Dynamik kann dazu führen, dass das kognitive System unerwartet auf Entitäten trifft, welche während der Erstellung des Domänenmodells nicht betrachtet wurden. Ein a priori erstelltes Hintergrundwissensmodell mit einer festen Menge von Konzepten kann somit nicht mehr ausreichend sein, um seine Aufgaben zu erfüllen.

Das objektorientierte Umweltmodell ist als zentrale Informationsdrehscheibe für kognitive Systeme entworfen. Daher sollte es auch in der Lage sein, mit Situationen umzugehen, in denen nicht modellierte Entitäten auftreten. Im Speziellen sollte es dem Umweltmodell möglich sein, das Vorliegen derartiger Situationen zu erkennen und die Situationen bewerten zu können. Weiterhin sollte es möglich sein, auch mit solchen Entitäten umgehen zu können, für welche im Hintergrundwissensmodell bisher keine Konzepte enthalten sind, zumindest falls dies die vorliegende Situation oder allgemein der Anwendungsfall erfordert. Der Besitz der genannten Fähigkeiten ermöglicht es einem Umweltmodell, auch in einer offenen Welt weiterhin angemessen funktionieren und dabei adaptiv auf unvorhergesehene Situationen reagieren zu können. Die durch die genannten Fähigkeiten beschriebenen Aufgaben und Tätigkeiten stellen einen Kerngegenstand dieser Arbeit dar und werden unter dem Begriff der adaptiven Umweltmodellierung zusammengefasst. Die Frage, unter welchen grundsätzlichen Annahmen und Prinzipien eine solche adaptive Umweltmodellierung durchgeführt werden kann und sollte, wird im folgenden Abschnitt dargestellt. In Abschnitt 3.2.2 werden dann die einzelnen Teilaufgaben dargelegt, die sich unter diesen Prinzipien für eine adaptive Umweltmodellierung ergeben.

3.2.1 Prinzipien für eine adaptive Umweltmodellierung

Die adaptive Umweltmodellierung betrifft primär die Verwaltung des Hintergrundwissensmodells. Eine mögliche Anpassung des Hintergrundwissens findet jedoch immer adaptiv in Bezug auf den im Weltmodell repräsentierten Umgebungszustand statt. Somit spielt auch das Weltmodell, dessen aktuelle Inhalte sowie allgemein die Art und Weise der Informationsrepräsentation im Weltmodell eine Rolle für die adaptive Umweltmodellierung. Weiterhin ist das objektorientierte Umweltmodell zur Anwendung in technisch kognitiven Systemen entworfen. Daher spielen auch Aspekte der menschlichen Kognition eine gewisse Rolle für die Informationsverarbeitung im objektorientierten Umweltmodell. Die Betrachtung solcher Aspekte kann somit auch für die adaptive Umweltmodellierung hilfreich sein, z. B. als motivierender Denkanstoß oder zur Festlegung einer Grundrichtung. Ein ähnliches Vorgehen findet sich z. B. auch beim Entwurf von kognitiven Architekturen im Bereich der Kognitionswissenschaften. Innerhalb dieses groben Rahmens folgt die in dieser Arbeit entworfene adaptive Umweltmodellierung gewissen Grundprinzipien, welche nachfolgend im Detail dargelegt werden. Diese Prinzipien wurden u. a. in [Kuw16] vorgestellt.

Wie bereits einleitend erwähnt, soll eine Anpassung des Hintergrundwissensmodells vor allem bedarfsgerecht erfolgen. Ein Hintergrundwissensmodell dient in der objektorientierten Umweltmodellierung hauptsächlich dazu, semantisches Vorwissen für die im Weltmodell enthaltenen Repräsentanten bereitzustellen. Der Bedarf für eine Anpassung des Hintergrundwissensmodells definiert sich somit vor allem in Bezug auf die aktuellen Inhalte des Weltmodells. Ist ein eingesetztes Hintergrundwissensmodell nicht in der Lage, für alle im Weltmodell enthaltenen Repräsentanten Vorwissen bereitzustellen, so besteht der Bedarf für eine Anpassung dieses Hintergrundwissensmodells. Eine Anpassung erfolgt dabei als eine Adaption an Teile des im Weltmodell dargestellten Umgebungszustandes.

Das Prinzip einer bedarfsgerechten Anpassung betrifft allgemein die Fragestellung, wann bzw. unter welchen Umständen eine Anpassung stattfinden

soll. Eine weitere wichtige Fragestellung betrifft den Aspekt, welche der Informationen im Weltmodell die Grundlage einer solchen Anpassung darstellen sollen. Hierbei spielt in dieser Arbeit das Prinzip der Relevanz eine wichtige Rolle. Die zugrunde liegende Frage ist dabei, welche der im Weltmodell enthaltenen Informationen über die Gegebenheiten der betrachteten Umgebung relevant genug sind, um im Falle eines festgestellten Änderungsbedarfs als Grundlage einer solchen Anpassung zu dienen. Anpassungen in einem Hintergrundwissensmodell werden in der adaptiven Umweltmodellierung durch das Erlernen neuer bzw. angepasster Konzepte umgesetzt. Dass Relevanz beim Erlernen neuer Konzepte ein wichtiges Prinzip darstellt, lässt sich auch durch eine Analogie zum menschlichen Lernen motivieren. Hier kann die Relevanz ebenfalls ein wichtiges Selektionskriterium für das zu Erlernende darstellen [Hen12].

Eine weitere Fragestellung, neben den Fragen nach dem Wann und der Datengrundlage des Lernens, betrifft das Wie einer Modellanpassung. Im Bereich der statistischen Modellierung werden sog. Informationskriterien zur Bewertung der Güte von Modellen genutzt [Kon08]. Eines der Prinzipien dieser Informationskriterien ist es, einen Ausgleich zwischen der Komplexität eines Modells und seiner Fähigkeit, gegebene Daten darstellen zu können, anzustreben. Modelle, welche einen solchen Ausgleich erreichen, werden dabei gegenüber anderen Modellen bevorzugt. Unter Anwendung dieses Prinzips lässt sich bereits oft die Überanpassung eines Modells an gegebene Daten verhindern und so dessen Generalisierungsfähigkeit verbessern.

Insgesamt sollen Anpassungen an einem Hintergrundwissensmodell auf eine für den Menschen nachvollziehbare Art und Weise erfolgen. Nachvollziehbarkeit betrifft dabei z. B. die Gründe, warum die Anpassung eines Modells stattfindet, die Datengrundlage dieser Anpassung, die Art, auf welche eine konkrete Anpassung durchgeführt wird sowie deren konkrete Änderungen an einem Modell. Weiterhin kann es auch relevant sein darzustellen, welche Auswirkungen die durchgeführten Änderungen haben, z. B. in Bezug auf die Aufgaben, für welche das Modell genutzt wird. Um eine bessere Nachvollziehbarkeit von Modellanpassungen zu ermöglichen, sollten diese möglichst anhand eines strukturierten Vorgehens durchgeführt werden.

Schließlich sollten sich auch die für eine adaptive Umweltmodellierung genutzten Methoden zur Modellanpassung am grundsätzlichen Prinzip der probabilistischen Informationsverwaltung im Umweltmodell orientieren.

3.2.2 Aufgaben der adaptiven Umweltmodellierung

Die adaptive Umweltmodellierung hat in dieser Arbeit das Ziel, dem objektorientierten Umweltmodell den Umgang mit Situationen zu ermöglichen, in welchen unvorhergesehene Entitäten auftreten. Dies betrifft Entitäten, für deren Typ im Hintergrundwissensmodell kein Konzept hinterlegt ist.

Eine erste Aufgabe stellt somit das Detektieren solcher Situationen dar. Dies kann auf zwei Ebenen erfolgen. Auf einer globalen Ebene ist die Qualität des Gesamtmodells betroffen. Diese Modellqualität bzw. Modellgüte beschreibt dabei, wie gut ein Hintergrundwissensmodell geeignet ist, die im Weltmodell dargestellten Repräsentanten beschreiben bzw. erklären zu können. Je weniger gut ein Hintergrundwissensmodell dazu in der Lage ist, je schlechter also seine Modellgüte ist, desto geringer ist auch sein Nutzen für die objektorientierte Umweltmodellierung. Die Modellgüte stellt daher ein übergeordnetes Kriterium zur Bewertung eines Hintergrundwissensmodells dar. In Teilen stellt die Modellgüte somit zugleich auch ein Kriterium für die Einsetzbarkeit des objektorientierten Umweltmodells als ein semantisches Umweltmodell dar. Die Problemstellung der gesamthaften Bewertung eines Hintergrundwissensmodells bzgl. seiner Güte wird im Rahmen der sog. quantitativen Modellbewertung in Kapitel 7 betrachtet.

Neben einer Betrachtung auf globaler Ebene kann auch auf lokaler Ebene das Vorliegen von nicht durch das Hintergrundwissensmodell erklärten Repräsentanten detektiert werden. Dabei stehen einzelne Repräsentanten im Vordergrund. Ziel dieser lokalen Betrachtungen ist es, diejenigen Repräsentanten zu identifizieren, welche nur schlecht durch die Konzepte des Hintergrundwissens beschrieben und erklärt werden können. Für diese Aufgabe können lokale Detektionsmaße bzgl. solcher schlecht beschriebener Repräsentanten definiert und eingesetzt werden. In dieser Arbeit erfolgt dies im Rahmen der adaptiven Wissensverwaltung, welche Kapitel 8 vorstellt.

Die adaptive Wissensverwaltung fasst all diejenigen Aufgaben zusammen, welche sich mit konkreten Anpassungs- und Verbesserungsmaßnahmen für ein als unzureichend bewertetes Hintergrundwissensmodell beschäftigen. Die quantitative Modellbewertung dient dabei als ein übergeordnetes Maß zur Steuerung dieser Wissensverwaltung. Neben der reinen Detektion des Auftretens von schlecht beschriebenen Repräsentanten auf lokaler Ebene müssen solche Repräsentanten auch im Sinne einer Buchhaltung verwaltet werden. Dies ist eine Voraussetzung zur Umsetzung des Prinzips der Relevanz von Modellanpassungen. Diese Verwaltung sorgt dafür, dass für eine durchzuführende Modellanpassung eine entsprechende Menge von relevanten Lernbeispielen als Datengrundlage zur Verfügung steht. Diese Lernbeispiele werden dabei aus denjenigen Repräsentanten ausgewählt, welche als schlecht beschrieben identifiziert wurden.

Schließlich müssen Modellanpassungen durchgeführt werden. Diese Aufgabe ist ebenfalls ein Teil der adaptiven Wissensverwaltung. Auch diese Modellanpassungen können und sollen von einer Modellgütebewertung geleitet werden. Modellanpassungen betreffen dabei das Erlernen neuer oder angepasster Konzepte aus den als Lernbeispielen bereitgestellten Repräsentanten und die Einordnung dieser Konzepte im Hintergrundwissensmodell.

Um neue Konzepte lernen und in ein Hintergrundwissensmodell einordnen zu können, muss ein solches Modell klar strukturiert sein und definierten Modellierungsprinzipien folgen. Dabei muss auch formal beschrieben werden, auf welche Weise Konzepte und ihre probabilistischen Attribute in der objektorientierten Umweltmodellierung repräsentiert werden. Auch müssen Festlegungen getroffen werden, wie welche Arten von Attributen unterschieden werden und was deren Bedeutung in der Umweltmodellierung ist oder auf welche Weise Wissen grundsätzlich in einem Wissensmodell strukturiert wird. Diesem Thema widmet sich Kapitel 4, in welchem ein Metamodell und eine Kern-Ontologie für die objektorientierte Umweltmodellierung definiert werden, welche anschließend als Grundlage der adaptiven Umweltmodellierung und für das Erlernen neuer Konzepte dienen.

Sowohl für die quantitative Modellbewertung als auch für die adaptive Wissensverwaltung ist die Zuordnung von Repräsentanten zu Konzepten von

Bedeutung. In Kapitel 6 wird daher auf das Thema der Repräsentant-zu-Konzept Zuordnung im objektorientierten Umweltmodell eingegangen, welches in den Kapiteln 7 und 8 wieder aufgegriffen wird.

3.3 Zusammenfassung

In diesem Kapitel wurde zunächst das zentrale Thema dieser Arbeit, die adaptive Umweltmodellierung, als eine wichtige Problemstellung innerhalb der objektorientierten Umweltmodellierung motiviert. Die adaptive Umweltmodellierung betrifft dabei die Fähigkeit eines Umweltmodells, adaptiv auf Situationen reagieren zu können, in welchen das in einem Hintergrundwissensmodell modellierte Vorwissen nicht mehr ausreichend ist. Es wurde dargelegt, dass eine solche adaptive Umweltmodellierung anhand von gewissen Prinzipien erfolgen sollte, darunter die Bedarfsgerechtigkeit, Relevanz und Nachvollziehbarkeit von Modellanpassungen sowie eine Ausgewogenheit zwischen Komplexität und Ausdrucksstärke eines Modells. Weiterhin wurden die Aufgaben innerhalb der adaptiven Umweltmodellierung vorgestellt. Wichtige Aspekte betreffen dabei die quantitative Bewertung der Güte eines Modells sowie die adaptive Verwaltung des repräsentierten Wissens.

4 Strukturierung und Repräsentation von Vorwissen

Das dieser Arbeit zugrunde liegende objektorientierte Umweltmodell OOWM zeichnet sich durch eine zweigeteilte Architektur aus. Den einen Teil dieser Architektur stellt die Weltmodell-Komponente dar, welche mit ihrer probabilistischen Informationsverwaltung detailliert bereits in Vorarbeiten zu dieser Arbeit diskutiert wird. Die Darstellung von klassenbezogenem Vorwissen in der Hintergrundwissens-Komponente wird in diesen Vorarbeiten allerdings nur konzeptuell betrachtet.

Ein Ziel dieser Arbeit ist es, das Vorgehen zur Repräsentation von Vorwissen für das OOWM detaillierter auszugestalten. In diesem Kapitel wird daher ein Ansatz entwickelt und vorgestellt, mit welchem Vorwissen in einer auf die Maßgaben der objektorientierten Umweltmodellierung zugeschnittenen Form repräsentiert werden kann. Bei diesen Maßgaben steht vor allem die probabilistische Modellierung der Eigenschaften von Entitäten im Vordergrund. Weiterhin muss allerdings auch eine Möglichkeit geschaffen werden, komplexes Vorwissen bzgl. einer Domäne strukturiert darstellen zu können und den weiteren Komponenten eines technisch kognitiven Systems zugänglich zu machen. Schließlich müssen auch die zusätzlichen Anforderungen beachtet werden, die sich aus der Annahme einer offenen Welt ergeben sowie der für diesen Fall notwendigen adaptiven Modellanpassung.

In Abschnitt 4.1 werden daher zunächst die Anforderungen an eine Repräsentation von Vorwissen in der objektorientierten Umweltmodellierung ermittelt und inhaltlich aufgearbeitet. Abschnitt 4.2 stellt darauf aufbauend das gewählte Vorgehen zur Strukturierung von Hintergrundwissensmodellen überblicksweise vor. Die Abschnitte 4.3 und 4.4 beschreiben

anschließend, wie dieses Vorgehen durch eine Metamodellierung und durch die Integration einer Top-Level Ontologie umgesetzt wurde. Abschnitt 4.5 beschreibt, wie auf Basis dieser Umsetzung dann spezifische Modelle zur Beschreibung von Anwendungsdomänen erstellt werden können. In Abschnitt 4.6 wird zur Demonstration des entwickelten Ansatzes schließlich ein beispielhaftes Domänenmodell für eine Haushaltsumgebung vorgestellt.

4.1 Anforderungen an die Repräsentation von Vorwissen

In diesem Abschnitt werden Anforderungen diskutiert, welche sich an eine Repräsentation von Vorwissen in der Hintergrundwissens-Komponente des objektorientierten Umweltmodells ergeben. Dazu werden zunächst die relevanten Eigenschaften eines Hintergrundwissensmodells, wie sie in Vorarbeiten genannt werden, in den Abschnitten 4.1.1 und 4.1.2 dargelegt. Anschließend werden in Abschnitt 4.1.3 weitergehende Aspekte diskutiert.

4.1.1 Allgemeine Anforderungen

In den Vorarbeiten zu dieser Arbeit wird ein Hintergrundwissensmodell für die objektorientierte Umweltmodellierung allgemein als eine Ontologie oder als eine Menge hierarchisch angeordneter Klassen mit Attributen und Relationen beschrieben [Ghe10b, Küh10]. Dabei legt das Hintergrundwissensmodell die Typen der für eine Domäne relevanten Entitäten und Beziehungen fest sowie die Eigenschaften, mit welchen diese beschrieben werden können [Bel09, Küh10]. Diese Eigenschaften werden weiterhin probabilistisch repräsentiert im Sinne von DoB-Verteilungen¹ und können unterschiedliche Skalenniveaus besitzen [Bey07, Ghe10b, Hei10]. Für die probabilistische Verwaltung von Informationen im Weltmodell werden weiterhin Parameterwerte benötigt, die dabei vom Typ einer Entität oder

¹ Wahrscheinlichkeitsverteilungen im Bayes'schen Sinne des Grades des Dafürhaltens („Degree-of-Belief“)

Beziehung sowie von der Art einer Eigenschaft abhängen können, wie z. B. ein Alterungsfaktor für Informationen [Hei10] oder ein Diskretisierungsparameter für Attribute [Bel12a]. Ein Hintergrundwissensmodell der objektorientierten Umweltmodellierung muss somit zumindest die nachfolgend genannten Aspekte der Wissensrepräsentation unterstützen:

- Repräsentation von Klassen von Entitäten zur Beschreibung der unterschiedlichen Entitätstypen,
- Repräsentation von Klassen von Relationen zur Beschreibung der unterschiedlichen Beziehungstypen,
- Repräsentation verschiedener Arten von Attributen zur Beschreibung der unterschiedlichen Eigenschaften von Entitäten und Relationen,
- Repräsentation von unsicherheitsbehafteten Attributwerten mittels Wahrscheinlichkeitsverteilungen,
- eine begriffliche Unterscheidung von Attributen unterschiedlicher Skalenniveaus sowie
- die Angabe von Parametern für Klassen von Entitäten und Relationen sowie für Arten von Attributen bzgl. Aspekten der probabilistischen Informationsverwaltung.

Das objektorientierte Umweltmodell ist weiterhin als ein Umweltmodell ausgelegt, welches nicht per se auf eine bestimmte Anwendungsdomäne beschränkt oder zugeschnitten ist. Bisherige Anwendungsbereiche umfassen z. B. die Situationsdarstellung für Videoüberwachungssysteme [Bau09] bzw. die Bereitstellung einer Gedächtnisstruktur für die Servicerobotik [Ghe10b] oder das autonome Fahren [Hei10]. Eine weitere, allgemeine Anforderung für die objektorientierte Umweltmodellierung ist es somit, unterschiedliche Hintergrundwissensmodelle für verschiedene Anwendungsdomänen einbinden und anwenden zu können. Die Prinzipien, nach denen solche Modelle aufzubauen sind, müssen somit unabhängig von einer konkreten Anwendungsdomäne beschrieben werden.

4.1.2 Anforderungen an die Repräsentation von Unsicherheiten

Die Repräsentation von Unsicherheiten mittels DoB-Verteilungen stellt einen wichtigen Aspekt der objektorientierten Umweltmodellierung dar, welcher diese z. B. auch von anderen Arten von Wissensbasen unterscheidet. Eine unsicherheitsbehaftete Repräsentation beschreibt stets auch einen probabilistischen Zusammenhang zwischen allen unsicherheitsbehafteten Größen eines Modells in Form einer gemeinsamen Wahrscheinlichkeitsverteilung dieser Größen. Die Repräsentation dieser gemeinsamen Wahrscheinlichkeitsverteilung kann auf unterschiedlich komplexe Art und Weise erfolgen. Die Komplexität betrifft dabei u. a. die Art der Modellierung von unsicherem Wissen sowie ebenfalls eine auf Basis eines solches Modells durchgeführte Inferenz, z. B. hinsichtlich ihrer Laufzeit. Charakterisieren lässt sich diese Komplexität im Hinblick auf die Unabhängigkeitsannahmen, welche bzgl. der beteiligten Größen getroffen werden. Für die probabilistische Informationsrepräsentation in der Weltmodell-Komponente des OOWM lassen sich nach Bauer [Bau09] z. B. folgende Stufen unterscheiden:

Keine Unabhängigkeitsannahmen: es wird von einer allgemeinen gemeinsamen Verteilung über den Attributen (als probabilistische Größen) aller Repräsentanten und Relationen des Weltmodells ohne weitere Unabhängigkeitsannahmen ausgegangen.

Die Annahme stochastisch unabhängiger Repräsentanten: alle Repräsentanten und Relationen im Weltmodell werden als jeweils stochastisch unabhängig voneinander angenommen. Die gemeinsame Verteilung aller probabilistischen Größen lässt sich somit faktorisiert als das Produkt der (gemeinsamen) Verteilungen aller Repräsentanten bzw. Relationen darstellen.

Die Annahme von bedingt stochastisch unabhängigen Attributen für stochastisch unabhängige Repräsentanten: Die Attribute jedes Repräsentanten bzw. jeder Relation werden zusätzlich als bedingt unabhängig angesehen, gegeben ihren Repräsentanten bzw. ihre Relation. Die (gemeinsame) Verteilung eines jeden Repräsentanten bzw. jeder Relation lässt

sich somit ebenfalls faktorisiert als das Produkt der DoB-Verteilungen aller enthaltenen Attribute darstellen.

Allgemein wird in Anwendungen des OOWM die zuletzt genannte stärkste Annahme der bedingt stochastisch unabhängigen Attribute verwendet.

Für die Hintergrundwissens-Komponente des OOWM stellt sich nun ebenfalls die Frage, auf welche Art und Weise unsicheres Wissen angemessen repräsentiert werden soll. Die Angemessenheit einer Repräsentation muss dabei anhand der Aufgaben beurteilt werden, für welche Vorwissen, und insbesondere unsicheres Wissen, in der objektorientierten Umweltmodellierung benötigt wird. Durch Vorwissen soll die Bedeutung von modellierten Domänen-Entitäten sowie weitere semantische Aspekte dem kognitiven System zugänglich gemacht werden [Ghe08, Küh10]. Dies betrifft z. B. Fragestellungen, wie welchem Zweck ein Objekt dient oder welche Fähigkeiten ein Objekt besitzt, sowie Fragestellungen, wie mit welchem Werkzeug eine gegebene Aufgabe gelöst werden kann. Vorwissen, welches für derartige Aufgaben benötigt wird, kann wie in Abschnitt 2.2.3 beschrieben prinzipiell über das Mittel der Vernetzung von modellierten Konzepten durch Relationen, also in Form von semantischen Netzen, erreicht werden. Eine weitere Aufgabe des Hintergrundwissensmodells ist es, die dynamische probabilistische Klassifikation von Repräsentanten des Weltmodells zu ermöglichen, auf Basis ihrer beobachteten Eigenschaften [Bau09, Ghe10b, Küh10]. Zu diesem Zweck werden die DoB-Verteilungen der Attribute eines Repräsentanten mit den Attribut-Verteilungen der modellierten Konzepte verglichen. Wurde ein Repräsentant erfolgreich klassifiziert, so besteht eine weitere Aufgabe darin, zusätzliche, bisher nicht beobachtete Informationen über diesen Repräsentanten bereitzustellen, in Form von erwarteten Werten für die entsprechenden Eigenschaften der repräsentierten Entität [Ghe10b, Küh10]. Dieser Vorgang wird als die Vervollständigung von Repräsentanten auf Basis von Vorwissen bezeichnet. Die letzten beiden Aspekte stellen dabei Anforderungen an die probabilistische Informationsrepräsentation im Hintergrundwissen der objektorientierten Umweltmodellierung. Diese Aspekte müssen somit durch eine entsprechende Repräsentation von unsicherem Wissen unterstützt werden.

Im Gegensatz zu anderen probabilistischen Modellen besteht allerdings nicht die allgemeine Anforderung, probabilistische Zusammenhänge zwischen Konzepten bzw. zwischen ihren Attributen derart im Hintergrundwissensmodell darzustellen, dass eine probabilistische Inferenz unterstützt werden kann. Eine solche Inferenz würde es ermöglichen, ausgehend von bestimmten gegebenen Attributwerten als Evidenzen, auf die Verteilung der Werte anderer Attribute (in anderen Konzepten) zu schließen. Derartige Aspekte werden nach den Entwurfsprinzipien des objektorientierten Umweltmodells OOWM als die Aufgaben von nachgelagerten Komponenten im technisch kognitiven System betrachtet, welchen das OOWM allerdings zu diesem Zweck seine Informationen zur Verfügung stellt¹.

Betrachtet man diese Anforderungen insgesamt, so kann für ein probabilistisches Hintergrundwissensmodell der objektorientierten Umweltmodellierung die Annahme von stochastisch unabhängigen Konzepten getroffen werden. Weiterhin können die Attribute eines Konzepts als bedingt unabhängig angenommen werden, gegeben das Konzept. Eine derartige Modellierung deckt einerseits die oben genannten Anforderungen ab und vereinfacht andererseits sowohl die Erstellung eines entsprechenden probabilistischen Hintergrundwissensmodells als auch dessen Anwendung (z. B. zur Klassifikation von Repräsentanten, aber auch bzgl. der quantitativen Modellbewertung wie in den Kapiteln 6 bzw. 7 beschrieben). Das Hintergrundwissensmodell kann somit mittels gleichartiger Unabhängigkeitsannahmen repräsentiert werden wie die Weltmodell-Komponente in [Bau09].

4.1.3 Weitergehende Aspekte

In dieser Arbeit steht die Annahme einer offenen Welt im Vordergrund. Diese Annahme besitzt auch Konsequenzen für ein Hintergrundwissensmodell.

¹ Ausgenommen von dieser Formulierung sei die Vervollständigung von Repräsentanten, in welcher, bedingt auf den Typ eines Repräsentanten, ebenfalls die Verteilung weiterer Attributwerte abgeleitet wird.

Im Speziellen muss z. B. davon ausgegangen werden, dass zur Entwurfszeit des Modells nicht alle Typen von relevanten Entitäten der betrachteten Domäne bekannt sind – und somit auch nicht als Konzepte modelliert werden können. Ein offenes Hintergrundwissensmodell muss es also unterstützen, zur Laufzeit um zusätzliche Konzepte erweitert zu werden, d. h. es muss grundsätzlich als erweiterbar entworfen werden. Erweiterbarkeit betrifft an dieser Stelle Aspekte wie die klare Strukturierung des Modells, das Anwenden von Entwurfsprinzipien oder Vorgehensmodellen während seiner Entwicklung, die Dokumentation des Modells sowie seine weitgehende Formalisierung. Beide zuletzt genannten Aspekte zielen dabei darauf ab, ein konsistentes Einordnen und Hinzufügen von neu gelernten Konzepten zumindest auf semi-automatische Weise unterstützen zu können.

Das Hinzufügen zusätzlicher Konzepte zum Hintergrundwissensmodell wird in dieser Arbeit als eine Aufgabe des Konzeptlernens interpretiert. Bei dieser Art der induktiven Inferenz wird aus einzelnen Beispielen auf das Allgemeine geschlossen. Für das objektorientierte Umweltmodell bedeutet dies, das aufgrund von beobachteten Entitäten, dargestellt als Repräsentanten des Weltmodells, auf neue Konzepte geschlossen wird, als Typen für diese Entitäten. Die Struktur des Hintergrundwissensmodells stellt dabei den induktiven Bias für dieses Konzeptlernen dar, da sie vorgibt, wie neu zu lernende Konzepte als Hypothesen repräsentiert werden können. Dies bedeutet im Speziellen, dass sowohl die Art und Weise, wie erworbene Umgebungsinformationen durch Repräsentanten im Weltmodell dargestellt werden, als auch die Art und Weise, wie Konzepte im Hintergrundwissen definiert und beschrieben werden, auf übergeordneter Ebene formal definiert werden müssen. Dies entspricht einem Metamodell für die Informationsrepräsentation in der objektorientierten Umweltmodellierung. Neu zu lernende Konzepte müssen dann nach den Vorgaben dieses Metamodells beschrieben werden. Weiterhin muss die Darstellung von Repräsentanten dahingehend kompatibel zur Darstellung von Konzepten sein, dass Repräsentanten und ihre Informationen als Lerndaten für die Definition neuer Konzepte Verwendung finden können. Diese Anforderungen bedeuten für die objektorientierte Umweltmodellierung im Wesentlichen, dass die Darstellung von Attributen in Repräsentanten und Konzepten durch ein

Metamodell formal definiert werden muss. Hier sind vor allem die möglichen Arten von Attributen in Bezug auf Aspekte wie ihr Skalenniveau, ihren Wertebereich oder weitere Metaeigenschaften festzulegen. In Abhängigkeit des Skalenniveaus eines Attributtyps kann dann z. B. definiert werden, wie während des Konzeptlernens gegebene Lernbeispiele für Attributwerte zu Konzeptattributen generalisiert werden.

Eine weitere grundlegende Annahme der Wissensmodellierung in der objektorientierten Umweltmodellierung ist es, dass ein Wissensmodell anwendungsrelevantes Vorwissen repräsentiert, welches a priori zur Entwurfszeit eines Systems von Experten erfasst, aufgearbeitet und schließlich formal repräsentiert wurde. Für die Erstellung eines solchen Wissensmodells spielt auch die Qualitätssicherung des Erstellungsprozesses eine wichtige Rolle, um ein konsistentes, qualitativ hochwertiges Wissensmodell zu erhalten. Trotz der Annahme einer offenen Welt wird also für die Wissensmodellierung in der adaptiven Umweltmodellierung nicht davon ausgegangen, dass ein Wissensmodell zur Laufzeit eines Systems neu erstellt werden muss, sei es von Null an oder auf Basis einer Skelettstruktur. Es wird dagegen angenommen, dass ein existierendes Wissensmodell an die Unabwägbarkeiten einer Domäne anzupassen ist und diese Anpassungen nur innerhalb eines gewissen Rahmens erfolgen sollen (z. B. im Hinblick auf die Anzahl der neuen oder geänderten Konzepte).

Das modellierte Wissen soll weiterhin so weit wie möglich nachvollziehbar und verständlich sein. Wird ein objektorientiertes Umweltmodell beispielsweise in einem technisch kognitiven System eingesetzt, welches der Unterstützung der menschlichen Entscheidungsfindung dient, so müssen vom System generierte Entscheidungsvorschläge transparent und nachvollziehbar sein. Ein formal repräsentiertes Wissensmodell leistet in solchen Systemen oft einen wesentlichen Beitrag zur Generierung solcher Vorschläge, z. B. durch die Ermöglichung von logischer Inferenz. Ein nicht nachvollziehbares Domänenmodell kann negative Auswirkungen auf die Transparenz der Entscheidungsfindung haben. Auch in Bezug auf die allgemeine Erweiterbarkeit eines Domänenmodells sowie konkrete Erweiterungen spielt die Nachvollziehbarkeit des Modells eine wichtige Rolle. Beispielsweise müssen

bereits zur Durchführung von manuellen Erweiterungen eines Modells dessen Grundprinzipien verstanden werden. Auch falls eine automatisch oder semi-automatisch durchgeführte Erweiterung überprüft oder bewertet werden soll, muss ein grundsätzliches Verständnis des Modells und der möglichen Auswirkungen einer Änderung vorhanden sein. Nachvollziehbarkeit und Verständlichkeit stellen somit weitere, nichtfunktionale Anforderungen an ein Hintergrundwissensmodell der Umweltmodellierung dar.

4.2 Gewähltes Vorgehen zur Strukturierung von Hintergrundwissen

In Kapitel 2.2 wurde der Stand der Technik von Verfahren zur Wissensrepräsentation für kognitive Systeme dargelegt. Nachfolgend werden diesem Stand die für ein Hintergrundwissensmodell in der objektorientierten Umweltmodellierung ermittelten Anforderungen gegenübergestellt, sowohl in Bezug auf semantische als auch probabilistische Aspekte. Dabei werden im Besonderen zwei Aspekte betrachtet:

- Mittels welcher Repräsentationsform bzw. Sprache kann Vorwissen im Hintergrundwissensmodell formal repräsentiert werden, um den oben genannten Anforderungen gerecht zu werden?
- Wie kann eine grundlegende Strukturierung für in einem Hintergrundwissensmodell zu modellierendes Wissen unter den genannten Anforderungen erfolgen? Können dazu existierende Top-Level Ontologien eingebunden werden?

Anschließend wird als Schlussfolgerung aus diesen Betrachtungen das für diese Arbeit gewählte Vorgehen zur Repräsentation und Strukturierung von Hintergrundwissen für die adaptive Umweltmodellierung beschrieben.

4.2.1 Bewertung der Stand-der-Technik Ansätze

An dieser Stelle erfolgt eine spezifische Bewertung und Zusammenfassung der in Kapitel 2 dargestellten relevanten Ansätze aus der Literatur. Spezifisch erfolgt die Betrachtung dabei in Bezug auf die dargelegten Anforderungen der objektorientierten und adaptiven Umweltmodellierung. Die Anteile der formalen Wissensrepräsentation und der inhaltlichen grundlegenden Strukturierung von Wissen werden getrennt dargestellt. Abgeleitet aus dieser Bewertung wird anschließend das eigene Vorgehen vorgestellt.

Wissensrepräsentation

Als Stand der Technik zur relationalen Wissensrepräsentation stellen Beschreibungslogiken einen guten Kompromiss zwischen Ausdrucksmächtigkeit der Sprache, Formalität, Inferenzmöglichkeiten sowie Werkzeugunterstützung für eine Verwaltung und Wartung erstellter Modelle mit vertretbarem Zeitaufwand dar. Die mittels einer Ontologie in Beschreibungslogik erstellte Terminologie zur Beschreibung einer Domäne ist weiterhin flexibel genug, um auch die Modellierung einer offenen Welt zu unterstützen, in welcher im Verlauf der Zeit neue Konzepte zu einem Domänenmodell hinzukommen können. Dem gegenüber stehen z. B. datenbankorientierte Modelle mit ihren festen Schemata für eine Domäne. Als konkrete Umsetzung einer Beschreibungslogik bietet insbesondere OWL (DL) den Vorteil einer standardisierten Sprache mit breiter Werkzeugunterstützung, z. B. in Form von Ontologie-Editoren mit Schnittstellen zur Integration von aktuellen Reasoning-Verfahren. Dies ermöglicht, zumindest für die relationalen Anteile eines Domänenmodells, bereits zur Entwicklungszeit die Durchführung von Konsistenzprüfungen für das Modell.

Allerdings unterstützt OWL per se nicht die Darstellung von unsicherheitsbehaftetem Wissen. Zu diesem Zweck können die in Kapitel 2.2.4 erwähnten logisch-probabilistischen Sprachen wie OPRML und PR-OWL verwendet werden. PR-OWL setzt dabei in Form einer transparenten Erweiterung auf

OWL auf und ermöglicht es somit, existierende OWL Modelle auch nachträglich um probabilistische Informationen zu ergänzen. Logisch-probabilistische Sprachen dienen dabei i. A. dazu, die gemeinsame Wahrscheinlichkeitsverteilung einer Menge von als Zufallsvariablen interpretierten Attributen von Objekten darzustellen. Das Ziel ist dabei, auf die Verteilung der möglichen Werte einer Teilmenge dieser Attribute schließen zu können, gegeben die Werte für eine andere Teilmenge der Attribute – also probabilistische Inferenz. Die logisch-probabilistischen Sprachen legen daher ihren Fokus darauf, probabilistische Zusammenhänge modular mittels lokaler Modelle darzustellen und auf Basis dieser Modelle Anfragen beantworten zu können. Eine Modellierung probabilistischer Attribute nach semantischen Kriterien steht dabei nicht im Vordergrund, wie beispielsweise eine Zuordnung von Zufallsvariablen zu Skalenniveaus. Darüber hinaus unterstützen viele Sprachen oft nur diskrete Zufallsvariablen, entweder per se (z. B. PRM [Kol98], OPRML [How09]) oder in ihrer praktischen Anwendung (z. B. PR-OWL [Cos05, Car11, Las11]). Stetige Merkmale müssen in diesen Sprachen daher zunächst entsprechend diskretisiert werden.

Die Eigenschaften von logisch-probabilistischen Sprachen und die Anforderungen an eine Wissensrepräsentation in der objektorientierten Umweltmodellierung besitzen somit eine nicht unwesentliche Schnittmenge, sind aber dennoch auch nicht deckungsgleich. Der Fokus der Wissensrepräsentation von logisch-probabilistischen Sprachen liegt klar auf einer Unterstützung der probabilistischen Inferenz, welche beim Umweltmodell OOWM ausgelagert ist auf andere Komponenten des kognitiven Systems. Der Fokus eines Hintergrundwissensmodells in der objektorientierten Umweltmodellierung ist die probabilistische Repräsentation von unsicherem Wissen in einer Form, welche die Erfüllung der oben genannten Aufgaben ermöglicht sowie die probabilistische Informationsverarbeitung des OOWM möglichst gut unterstützt. Dabei müssen nicht nur diskrete, sondern auch stetige Merkmale in Form von DoB-Verteilungen repräsentiert werden können. Weiterhin müssen probabilistische Attribute auch mit semantischen Information annotiert werden können, wie den ihnen zugrunde liegenden Skalenniveaus, Maßeinheiten etc.

Als Folge dieser Eigenschaften von logisch-probabilistischen Sprachen kann in dieser Arbeit nicht direkt auf solchen Sprachen aufgesetzt werden. Der für diese Arbeit gewählte Ansatz zur Strukturierung von Hintergrundwissensmodellen setzt somit direkt auf OWL (2 DL) auf und erweitert dieses um eine eigene Möglichkeit zur Darstellung der benötigten probabilistischen Informationen. Die Verwendung von OWL als Basis ermöglicht jedoch immerhin eine gewisse Grund-Kompatibilität zur logisch-probabilistische Sprache PR-OWL. Nachgelagerte Komponenten des kognitiven Systems können z. B. die Terminologie des Hintergrundwissensmodells und die modellierten probabilistischen Informationen unter Anwendung von einfachen Transformationen nach PR-OWL überführen. So kann das in einem objektorientierten Umweltmodell modellierte Wissen als Grundlage zur Definition weiterer, auf Inferenz ausgerichteter Modelle genutzt werden.

Strukturierung von Wissen

Neben der Repräsentationssprache, in welcher Wissen in einem Hintergrundwissensmodell dargestellt werden soll, sind auch zwei weitere Entwurfsaspekte für die adaptive Umweltmodellierung interessant. Dies ist einerseits die grundlegende (d. h. kategorische) Strukturierung des darzustellenden Wissens in einem Hintergrundwissensmodell sowie andererseits die Frage, ob zu diesem Zweck auf einer existierenden Top-Level Ontologie aufgesetzt werden kann und soll. In Abschnitt 2.2.4 wurde ein Überblick über verschiedene relevante Stand-der-Technik Ansätze zur Umweltmodellierung und existierende Wissensbasen gegeben. Einige der betrachteten Umweltmodelle nutzen dabei direkt eine logisch-probabilistische Sprache zur Wissensrepräsentation, z. B. in den Bereichen der Lagedarstellung [How09, Las11] oder des autonomen Fahrens [Sch14]. Die Ansätze beschreiben meist weniger umfangreiche Domänenmodelle und verzichten auf die explizite Einbindung einer Top-Level Ontologie. Im Bereich der Servicerobotik setzen viele der betrachteten Ansätze auf OWL DL als Repräsentationssprache auf und nutzen dieses zur Erstellung eigener Wissensmodelle (z. B. [Ten09, Lim11, Lem11]). Zur Strukturierung dieser Wissensmodelle findet dabei häufig die Top-Level Ontologie der Wissensbasis Cyc [Len95]

(in ihrer quelloffenen Variante OpenCyc) Verwendung. Weitere Ansätze (z. B. [Dao13]) setzen auch DOLCE [Mas03] als Top-Level Ontologie ein.

Der Einsatz von Cyc als Top-Level Ontologie ermöglicht es, auf die große Menge von modellierten Konzepten in der Wissensbasis von Cyc zugreifen zu können. Weiterhin sind Abbildungen dieser Konzepte zu weiteren Wissensmodellen, wie z. B. WordNet [Mil95], definiert. Cyc wurde allerdings nicht dafür entwickelt, probabilistische Informationen für eine Erkennung von Objekten darstellen zu können. Weiterhin ist Cyc proprietär. Alternativen zu Cyc sind durch die Top-Level Ontologien DOLCE¹ [Mas03] und SUMO² [Nil01] gegeben. SUMO stellt dabei eine frei verfügbare und standardisierte Top-Level Ontologie dar, welche aus der Verschmelzung von vorhergehenden Ontologien entstanden ist. DOLCE ist ebenfalls frei verfügbar und soll zur grundlegenden Strukturierung von Wissen im Bereich der menschlichen Kognition und Sprache dienen. Beide Top-Level Ontologien wurden unter internationaler Beteiligung entwickelt und repräsentieren somit einen breiteren Konsens [Sch06]. Sie sind jeweils explizit dafür gedacht, als Startpunkt für die Entwicklung eigener Domänenmodelle zu dienen. Auch DOLCE und SUMO beschreiben keine direkten Möglichkeiten, um probabilistische Attribute für Konzepte darzustellen. Allerdings sind sie explizit für ihre Erweiterung ausgelegt. Bei der Entwicklung der Wissensstruktur in DOLCE wurde weiterhin besondere Aufmerksamkeit auf die Einhaltung von Prinzipien der formalen Ontologie, eine Dokumentation von Entwurfsentscheidung sowie eine umfassende Axiomatisierung gelegt [Mas03]. Demgegenüber wurden für andere Top-Level Ontologien in [Gua04] beispielsweise unter Anwendung der OntoClean Entwurfsmethodik für formale Ontologien Defizite in der Wissensstrukturierung festgestellt. Weitere Ansätze wie WordNet [Mil95], ConceptNet [Liu04], DBPedia [Leh15] oder YAGO [Reb16] stellen ebenfalls große Wissensbasen für Allgemeinwissen dar, sind aber nicht explizit als Top-Level Ontologien ausgelegt oder formal logisch repräsentiert, sondern stellen semantisch vernetztes Wissen dar.

¹ Descriptive Ontology for Linguistic and Cognitive Engineering

² Suggested Upper Merged Ontology

Um den Anforderungen in der objektorientierten Umweltmodellierung nach Erweiterbarkeit, Nachvollziehbarkeit und Domänenunabhängigkeit einer Top-Level Ontologie Rechnung zu tragen, wurde in dieser Arbeit DOLCE als Top-Level Ontologie und Modell für eine grundlegende Wissensstrukturierung ausgewählt. Für DOLCE steht eine Umsetzung¹ in OWL DL frei zur Verfügung. Die Axiomatisierung dieser Umsetzung ist allerdings aufgrund der Sprachrestriktionen von OWL DL gegenüber der ursprünglichen Beschreibung in Prädikatenlogik entsprechend reduziert. Diese Umsetzung dient in Verbindung mit der grundlegenden Wissensstrukturierung im Folgenden als Grundlage, um die Repräsentation von probabilistischen Informationen für die objektorientierte Umweltmodellierung einzuführen.

4.2.2 Gewähltes Vorgehen

In dieser Arbeit werden nun Möglichkeiten betrachtet, Vorwissen strukturiert und formal in der Hintergrundwissens-Komponente des objektorientierten Umweltmodells abzulegen. Dabei soll ebenfalls das Erlernen neuer Konzepte auf Basis von Beobachtungsinformationen im Weltmodell ermöglicht werden. Die objektorientierte Umweltmodellierung ist ihren Grundsätzen nach ein domänen-agnostischer Ansatz. Erst für eine konkrete Anwendung in einer gegebenen Domäne wird das Hintergrundwissen spezialisiert, z. B. durch ein entsprechendes Domänenmodell. Eine Strukturierung des Vorwissens muss aus diesem Grund auf einer übergeordneten Ebene erfolgen. Zu diesem Zweck wird für die Hintergrundwissens-Komponente in dieser Arbeit zunächst ein Metamodell auf konzeptueller Ebene definiert. Durch dieses Metamodell wird das grundsätzliche Vorgehen zur Repräsentation von probabilistischen Informationen für Attribute und Relationen festgelegt. Anschließend wird die prinzipielle kategorische Strukturierung von Wissen betrachtet und durch Auswahl und Integration der Top-Level Ontologie DOLCE spezifiziert. Dies wird in Abschnitt 4.4 dargestellt.

¹ DOLCE Lite, siehe: <http://www.loa.istc.cnr.it/dolce/overview.html> (letzter Abruf: 08.05.2020)

Metamodelle werden verwendet, wenn ein Modell selbst Gegenstand der Modellierung ist [Str13b]. Soll beschrieben werden, nach welchen Prinzipien mögliche Domänenmodelle der objektorientierten Umweltmodellierung aufgebaut sind, so stellt sich diese Beschreibung ebenfalls als ein Metamodell dar. Ein Metamodell legt dabei die Sprache fest, in welcher das zu definierende Modell formuliert werden kann [Str13b]. Für die objektorientierte Umweltmodellierung soll ein Metamodell im Speziellen solche Informationen bereitstellen, welche als Metawissen von anderen Anteilen des Umweltmodells zur Durchführung ihrer Aufgaben, z. B. einer Informationsverarbeitung, benötigt werden. Dies betrifft beispielsweise die Frage, wie die Merkmale einer Entität repräsentiert werden (z. B. bzgl. Skalenniveau und Wertebereich) und wie diese verarbeitet werden können, aber nicht die Verarbeitung selbst. Konkret dient die Metamodellierung für Hintergrundwissensmodelle in dieser Arbeit mehreren Zwecken:

- Zunächst soll eine einheitliche konzeptuelle Struktur und Begriffswelt für die Modellelemente, die zur Beschreibung von Anwendungsdomänen verwendet werden, geschaffen werden.
- Weiterhin soll auch die Bedeutung derjenigen Modellelemente, die in der internen Informationsverarbeitung Anwendung finden, präzise definiert werden (z. B. verschiedene Arten von Attributen).
- Im Speziellen soll durch ein Metamodell grob der induktive Bias festgelegt werden, welcher für ein generalisierendes Lernen neuer Konzepte aus wenigen Beobachtungen benötigt wird. Ein Metamodell strukturiert dabei auf gewisse Weise den Raum der Hypothesen, als welche neu zu lernende Konzepte aufgefasst werden können.
- Weiterhin soll auch die Interoperabilität des objektorientierten Umweltmodells auf semantischer Ebene gefördert werden, indem Schnittstellen und Datenstrukturen beschrieben werden, mit welchen z. B. von Sensoren gemachte Beobachtungen beschrieben und an das Umweltmodell übergeben werden können.

Dabei müssen in einem Metamodell für das Hintergrundwissen der objektorientierten Umweltmodellierung zumindest folgende Aspekte betrachtet und festgelegt werden:

- Repräsentation von Klassen von Entitäten (Typen) mit Attributen und Relationen,
- Repräsentation von unsicherheitsbehafteten Attributwerten mittels DoB Wahrscheinlichkeitsverteilungen,
- Repräsentation von unsicherheitsbehafteten Relationen sowie
- Unterscheidung von Attributen mit unterschiedlichen Skalenniveaus.

Die zu diesem Zweck im Metamodell definierten Modellelemente sollen, soweit möglich, auch zueinander in Beziehung gesetzt werden, im Sinne eines semantischen Modells. Darüber hinaus betreffen speziellere Aspekte der Metamodellierung

- die Unterscheidung von unterschiedlichen Arten von Attributen, z. B. in Bezug auf ihre Bedeutung für eine adaptive Umweltmodellierung,
- die Angabe von Maßeinheiten für von Sensoren beobachtete Werte,
- die Darstellung der probabilistischen Typzuordnung für Repräsentanten des Weltmodells zu Klassen (Konzepten) im Hintergrundwissen.

Weiterhin sind auch Aspekte wie die Darstellung von Ort und Zeit interessant, diese werden allerdings in Verbindung mit der gewählten Top-Level Ontologie diskutiert. Nachfolgend wird nun das für die adaptive Umweltmodellierung entworfene Metamodell im Detail vorgestellt.

4.3 Metamodellierung

Das in dieser Arbeit entworfene Metamodell wird zunächst abstrakt beschrieben, bevor es im Weiteren detaillierter vorgestellt wird. Das beschriebene Modell stellt dabei eine Anpassung und Weiterentwicklung des initialen, in [Kuw13c] beschriebenen Modells dar. In Abbildung 4.1 ist daher zuerst eine abstrakte Sicht auf die wesentlichen Aspekte eines Hintergrundwissensmodells der objektorientierten Umweltmodellierung dargestellt, welche die in den genannten Vorarbeiten erwähnten Anteile aufgreift. Im Hintergrundwissen sollen die verschiedenen relevanten Arten von Entitäten einer Anwendungsdomäne modelliert werden. Diese werden durch

das Modellelement „Domänen-Entität“ repräsentiert, die eine Klasse mit einem eindeutigen Namen darstellt, welche über Oberklassen hierarchisch angeordnet sein kann. Beschrieben wird jede Art von Domänen-Entität durch ihre Attribute, dargestellt durch das Modellelement „Attribut“. Ein Attribut bezieht sich dabei auf eine Qualität (d. h. eine Eigenschaft wie Länge, Farbe, Form etc.) und wird auf einem bestimmten Skalenniveau mit einem gegebenen Wertebereich beschrieben. Jedes Attribut wird in seiner Ausprägung durch eine Wahrscheinlichkeitsverteilung repräsentiert, ggf. unter Angabe einer Maßeinheit. Unterschiedliche Domänen-Entitäten und Arten von Domänen-Entitäten können weiterhin durch Relationen verbunden sein, welche durch das Modellelement „Relation“ dargestellt werden. Relationen besitzen einen Definitionsbereich und einen Wertebereich, die jeweils festlegen, zwischen welchen Arten von Domänen-Entitäten eine entsprechende Beziehung bestehen darf.

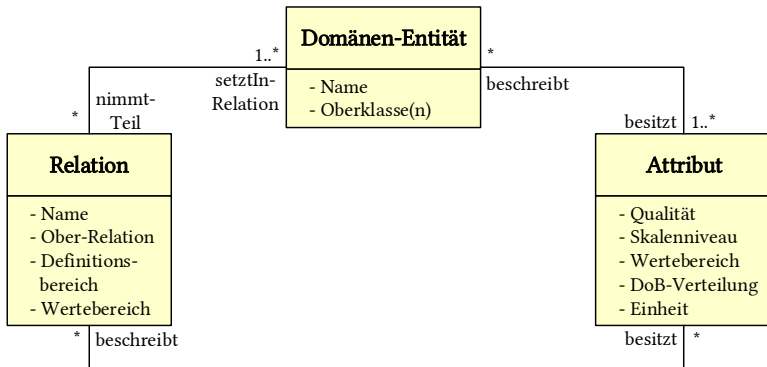


Abbildung 4.1: Grundsätzliche Elemente eines Hintergrundwissensmodells der objektorientierten Umweltmodellierung in Erweiterung zu [Kuw13c] (die Beziehungen sind dabei in UML Notation mit Multiplizitäten angegeben).

Zusätzlich zu den in Abbildung 4.1 gezeigten Anteilen müssen weitere Informationen spezifiziert werden können, welche als Parameterwerte für die probabilistische Informationsverarbeitung dienen. Für Typen von Domänen-Entitäten betrifft dies z. B. einen klassenspezifischen Alterungsfaktor [Hei10], welcher ein Absinken der Existenzwahrscheinlichkeit von

Instanzen dieses Typs über die Zeit beschreibt. Für Typen von Relationen und für Arten von Attributen wird auf diese Informationen nachfolgend bei der detaillierten Darstellung des Metamodells eingegangen. Im Wesentlichen entspricht das auf abstrakter Ebene beschriebene Metamodell einem Entity-Relationship-Modell mit zusätzlichen probabilistischen Attributen, Skalenniveaus und Einheiten als expliziten Modellelementen.

4.3.1 Grundlegende Darstellung von Attributen

Eine zentrale Rolle für die Umweltmodellierung spielen die Attribute, über welche die definierenden Eigenschaften unterschiedlicher Typen von Entitäten festgelegt werden und mittels derer z. B. die probabilistische Klassifikation von Repräsentanten des Weltmodells erfolgt. Auf die Darstellung von Attributen im Hintergrundwissen wird daher an dieser Stelle detaillierter eingegangen. Attribute werden beim gewählten Vorgehen in Form eines semantischen Netzes repräsentiert, wie in Abbildung 4.2 dargestellt.

Qualität Dabei referenziert ein Attribut zunächst die Qualität, welche es repräsentieren soll (z. B. eine Länge). Wie genau der Begriff einer Qualität als eine ontologische Kategorie zu verstehen ist, wird in Abschnitt 4.4 im Rahmen der gewählten Top-Level Ontologie erläutert. Qualitäten können an sich ebenfalls in einem hierarchischen Modell dargestellt werden und müssen über eine erklärende Beschreibung verfügen. Zusätzlich werden Qualitäten über Angaben wie ihr Skalenniveau oder die Art ihrer Verwendung innerhalb eines Anwendungsfalls spezifiziert.

Skalenniveau Skalenniveaus werden im gewählten Vorgehen als einfache Symbole aus einem festen Wertevorrat repräsentiert. Sie dienen dabei hauptsächlich als Markierungen. Diese Markierungen ermöglichen es, dass ein Attribut innerhalb des objektorientierten Umweltmodells oder außerhalb in weiteren Komponenten des kognitiven Systems anhand seines Skalenniveaus unterschiedlich behandelt und verarbeitet werden kann. Für die modellierten Skalenniveaus wird eine zugrunde liegende Halbordnung angenommen, welche sich über folgende Ketten definiert:

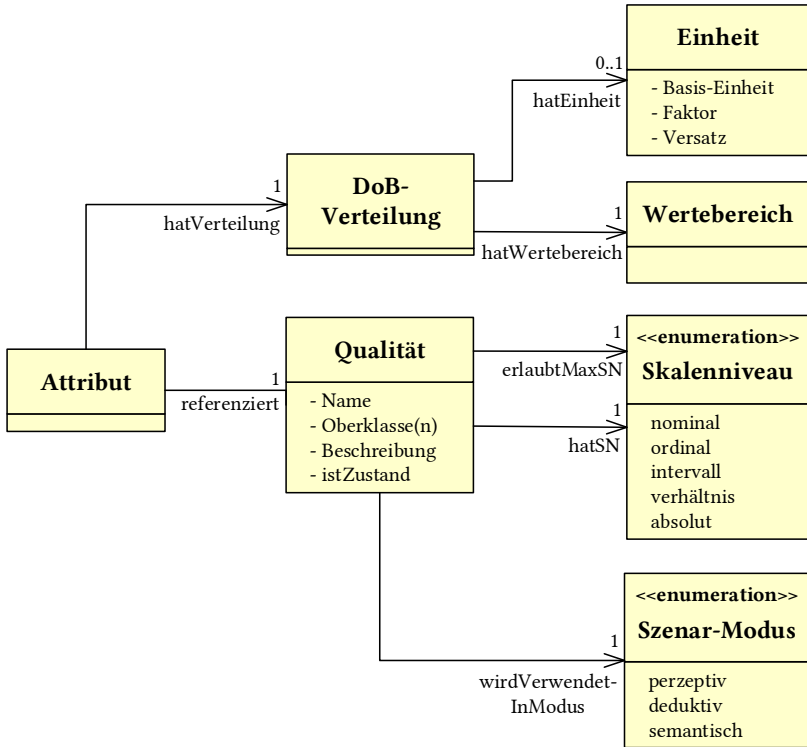


Abbildung 4.2: Modellierung von probabilistischen Attributen für die adaptive Umweltmodellierung (in UML Notation mit Multiplizitäten für Beziehungen). Ein Attribut wird dabei durch ein semantisches Netz repräsentiert.

- Nominalskala \leq Ordinalskala \leq Intervallskala \leq Verhältnisskala,
- Nominalskala \leq Ordinalskala \leq Absolutskala.

Diese Halbordnung ist z. B. für die Festlegung des maximal unterstützten Skalenniveaus einer Qualität in einem Domänenmodell relevant.

Szenarmodus Neben dem Skalenniveau ist auch eine weitere Eigenschaft von Qualitäten für die adaptive Umweltmodellierung von Interesse. Diese Eigenschaft betrifft die Art und Weise, wie Informationen über die konkrete

Ausprägung einer Qualität in einem beobachteten Objekt gewonnen werden können, und wird als Szenarmodus bezeichnet. Mit dieser Bezeichnung soll zum Ausdruck kommen, dass diese Eigenschaft vom konkreten Anwendungsszenario abhängt, genauer gesagt von der Sensorik, die einem gegebenen kognitiven System im Anwendungsfall zur Verfügung steht. Szenar Modi werden ebenfalls als einfache Symbole aus einem festen Wertevorrat repräsentiert. Ein perzeptiver Szenarmodus für eine Qualität beschreibt dabei, dass im betrachteten Anwendungsfall entsprechende Ausprägungen der Qualität in beobachteten Objekten mittels der verfügbaren Sensorik wahrgenommen und ermittelt werden können. Ist eine solche Erfassung nicht möglich, so besitzt eine Qualität entweder einen deduktiven oder einen semantischen Szenarmodus. Ein semantischer Szenarmodus beschreibt, dass Werte für diese Qualität nur anhand des im Wissensmodell modellierten Vorwissens gewonnen werden können. Ein deduktiver Szenarmodus beschreibt dahingegen, dass Ausprägungen für Objekte zwar nicht direkt beobachtet werden können, diese allerdings aus den Ausprägungen weiterer Qualitäten abgeleitet werden können, ggf. unter Betrachtung der Historie dieser Ausprägungen.

Zustandsbezogene Qualitäten Eine weitere Eigenschaft von Qualitäten betrifft die Aussage, ob sie in Objekten einen Zustand beschreiben oder ein unveränderliches Merkmal darstellen. Ein unveränderliches Merkmal wird dabei als zeitlich konstant angenommen, ein Zustand kann sich im Verlauf der Zeit ändern. Für Aufgaben wie eine Identifikation oder Klassifikation von in der Umgebung beobachteten Objekten ist eine derartige Unterscheidung von Interesse. So werden für diese Aufgaben im Allgemeinen unveränderliche Merkmale genutzt. Auch für die Zuordnung von beobachteten Objekten zu Konzepten im Hintergrundwissen werden in der objektorientierten Umweltmodellierung keine zustandsbezogenen Qualitäten eingesetzt.

Verwaltungsinformationen für Qualitäten Nicht dargestellt in Abbildung 4.2 sind als weitere Eigenschaften einer Qualität diejenigen Informationen, welche als Parameterwerte für die probabilistische Informationsverwaltung von Qualitäten dienen. Dies sind z. B. ein Diskretisierungsparameter, welcher die Intervallgröße für die Diskretisierung eines stetigen Attributs dieser Qualität beschreibt, oder ein Alterungsfaktor, welcher zur probabilistischen Prädiktion einer Wahrscheinlichkeitsverteilung dieser Qualität verwendet werden kann.

Schrittweise Spezifikation von Qualitäten Welche Qualitäten für eine Domäne und einen Anwendungsfall konkret betrachtet werden, wird in einem entsprechenden Domänenmodell festgelegt. In diesem Modell müssen pro Qualität auch Skalenniveau, Szenarmodus und Veränderlichkeit festgelegt werden. Diese Festlegung kann dabei schrittweise erfolgen: auf der Ebene eines Domänenmodells kann zunächst nur eine grobe Festlegung der Eigenschaften einer Qualität erfolgen, detaillierte Angaben können anschließend auf der Ebene eines untergeordneten Anwendungsmodells vorgenommen werden. Im in dieser Arbeit gewählten Vorgehen kann daher z. B. das Skalenniveau einer Qualität auf zwei unterschiedliche Arten angegeben werden. Auf der Ebene eines Domänenmodells wird dabei für eine Qualität das maximal erlaubte Skalenniveau festgelegt, mit welchem Attribute zu dieser Qualität repräsentiert werden dürfen („erlaubtMaxSN“). Für einen konkreten Anwendungsfall kann dann das tatsächlich verwendete Skalenniveau spezifiziert werden („hatSN“), welches dem maximal erlaubten Skalenniveau im Sinne der zuvor beschriebenen Halbordnung untergeordnet sein muss. In welchem Szenarmodus eine Qualität verwendet wird, wird im Regelfall ebenfalls erst für den konkreten Anwendungsfall festgelegt. In Abschnitt 4.5 wird auf diesen Aspekt der schrittweisen Erstellung von Hintergrundwissensmodellen nochmals eingegangen.

Wahrscheinlichkeitsverteilungen

Der zweite wichtige Aspekt bei der Darstellung von Attributen, neben der repräsentierten Qualität, ist die Beschreibung von unsicherheitsbehafteten

Attributwerten. Zu diesem Zweck werden DoB Wahrscheinlichkeitsverteilungen verwendet und mit einem Attribut verknüpft. Jeder Verteilung ist dabei ein bestimmter Wertebereich zugeordnet. In Abhängigkeit dieses Wertebereichs und ihres Skalenniveaus lassen sich verschiedene Arten von Attributen unterscheiden. Auf die Details bzgl. der Repräsentation von unsicherheitsbehafteten Werten und die unterschiedlichen Arten von Attributen wird im Abschnitt 4.3.2 genauer eingegangen. Beschreibt ein Attribut ein stetiges Merkmal, so muss neben einem reinen Zahlenwert auch dessen Maßeinheit angegeben werden. Dies gilt für deterministische Attributwerte genauso wie für probabilistische. Im in dieser Arbeit gewählten Vorgehen kann eine Wahrscheinlichkeitsverteilung daher eine Maßeinheit referenzieren.

Maßeinheiten Einer Wahrscheinlichkeitsverteilung kann eine Maßeinheit zugeordnet werden. Aus Gründen der Interoperabilität werden in dieser Arbeit für eine Qualität unterschiedliche Maßeinheiten unterstützt. Jede Einheit referenziert daher eine entsprechende Basiseinheit und gibt einen Umrechnungsfaktor sowie einen Versatz an, welche zusammen beschreiben, wie diese Einheit unter Anwendung einer affinen Funktion in die Basiseinheit umgerechnet wird.

4.3.2 Probabilistische Repräsentation von Attributwerten

Nachdem vorausgehend die grundlegende Repräsentation von Attributen in der adaptiven Umweltmodellierung vorgestellt wurde, soll nun spezifisch die Darstellung unsicherheitsbehafteter Attributwerte betrachtet werden. In dieser Arbeit werden dazu verschiedene Arten von Attributen unterschieden, hauptsächlich anhand der repräsentierten Skalenniveaus. Den unterschiedlichen Arten von Attributen sind dabei analog unterschiedliche Typen von Wahrscheinlichkeitsverteilungen zugeordnet.

Arten von probabilistischen Attributen Als Attribute werden zunächst diskrete von stetigen Attributen unterschieden, in Bezug auf die verschiedenen Arten von repräsentierten Merkmalen. Als diskrete Attribute werden

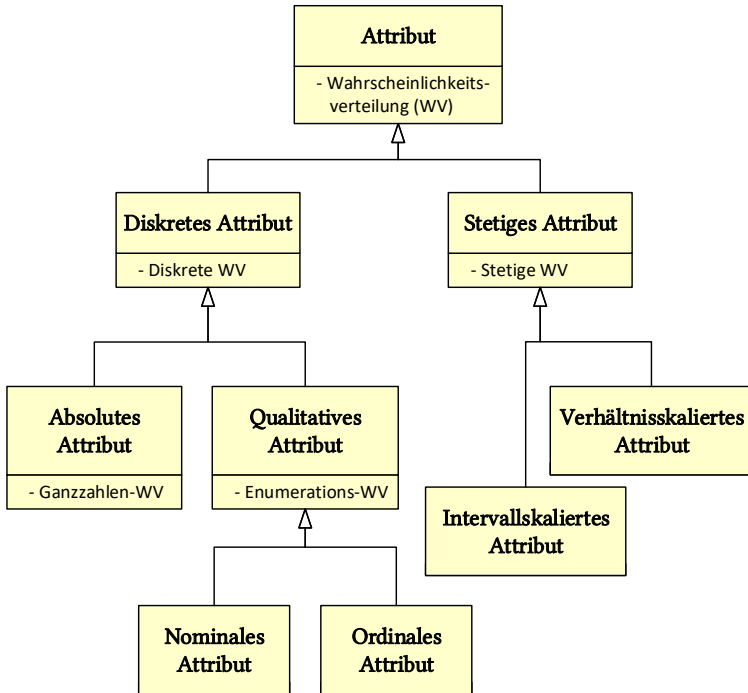


Abbildung 4.3: Definierte Arten von probabilistischen Attributen in der adaptiven Umweltmodellierung. Attribute werden anhand ihrer Skalenniveaus unterschieden und sind mit Bezug zum für sie genutzten Typ von Wahrscheinlichkeitsverteilung dargestellt (Erweiterung zu [Kuw13c]).

absolute, nominale und ordinale Attribute unterscheiden, welche jeweils die entsprechenden Skalenniveaus repräsentieren. Nominale und ordinale Attribute werden zu qualitativen Attributen zusammengefasst. Als stetige Attribute sind intervall- und verhältnisskalierte Attribute definiert. Abbildung 4.3 stellt die im Metamodell definierten Arten von Attributen dar. In Abbildung 4.4 werden die definierten Typen von Wahrscheinlichkeitsverteilungen gezeigt.

Typen von Wahrscheinlichkeitsverteilungen Für Wahrscheinlichkeitsverteilungen sind ebenfalls diskrete und stetige Typen definiert. Als diskrete

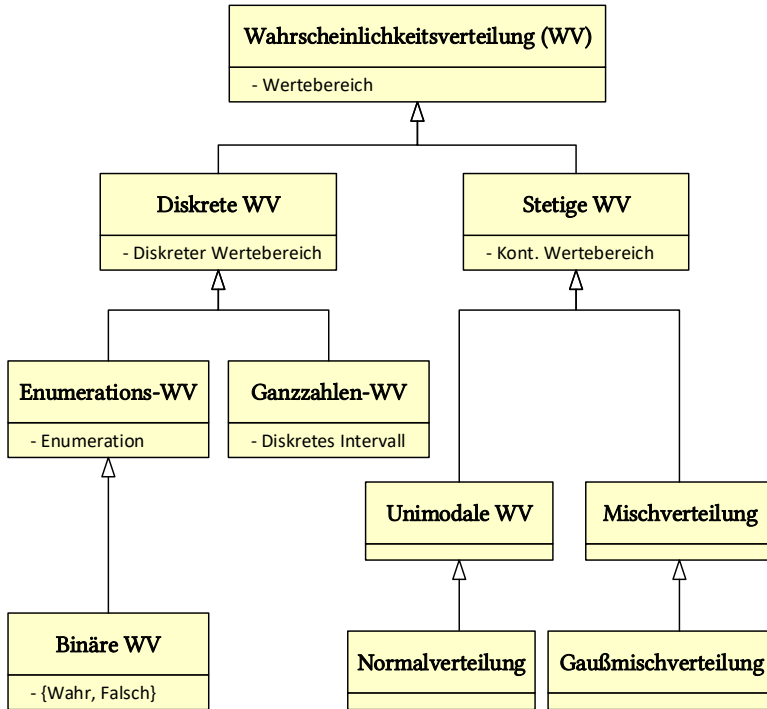


Abbildung 4.4: Definierte Typen von Wahrscheinlichkeitsverteilungen in der adaptiven Umweltmodellierung und ihre Wertebereiche (nach [Kuw13c]).

Wahrscheinlichkeitsverteilungen sind Verteilungen über den ganzen Zahlen \mathbb{Z} als ihrem Wertebereich und über symbolischen Enumerations als Wertebereich definiert. Diese Verteilungen werden entsprechend von absoluten bzw. qualitativen Attributen referenziert. Als stetige Verteilungen werden unimodale Verteilungen und Mischverteilungen unterschieden, welche beide von intervall- oder verhältnisskalierten Attributen referenziert werden können. Konkret sind Normalverteilungen als unimodale Verteilungen sowie Gaußmischverteilungen definiert. Weiterhin können als unimodale

Verteilungen abgeschnittene Versionen der Normalverteilung über relevanten Einschränkungen der reellen Zahlen als Wertebereiche genutzt werden, z. B. positive bzw. nicht-negative Normalverteilungen.

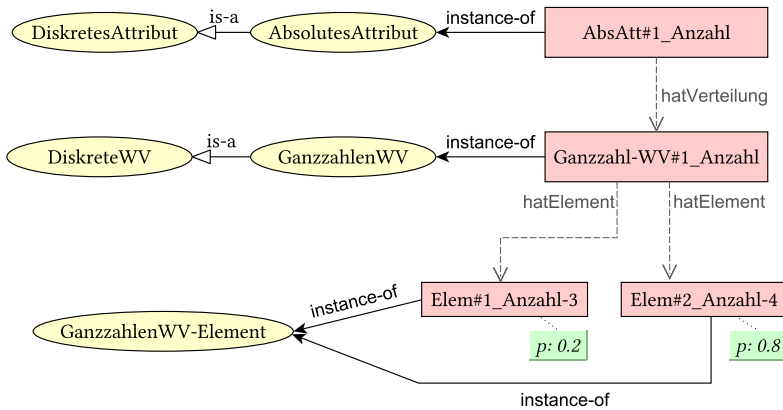
In Abbildung 4.5 sind zwei Beispiele dafür dargestellt, wie ein probabilistisches Attribut in der adaptiven Umweltmodellierung konkret repräsentiert wird. Als Attribut wird dabei eine Anzahl bzw. eine binäre Existenzvariable dargestellt. Konzepte werden als gelbe Ellipsen gezeigt, Instanzen dieser Konzepte als rote Rechtecke. Die Werte des Anzahlattributs werden durch eine diskrete Wahrscheinlichkeitsverteilung über den ganzen Zahlen repräsentiert, welche nur für die zwei gezeigten Elemente (Zahlen) eine von Null verschiedene Wahrscheinlichkeit annimmt. Die Existenzvariable wird über einer binären Enumeration repräsentiert, deren Symbolen Wahrscheinlichkeiten zugeordnet werden.

4.3.3 Probabilistische Repräsentation von Beziehungen

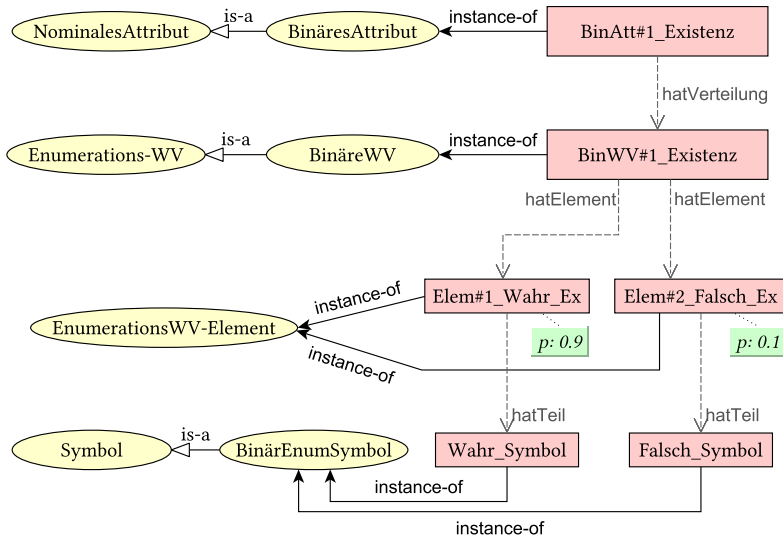
In der objektorientierten Umweltmodellierung werden neben Attributen von Entitäten auch die Beziehungen zwischen Entitäten auf eine probabilistische Weise repräsentiert [Bey07, Ghe10b, Hei10]. Anforderungen an solche probabilistische Relationen existieren in Vorarbeiten zur objektorientierten Umweltmodellierung nur vage als die folgenden Aussagen:

- Relationen besitzen ebenfalls Attribute, und diese Attribute werden probabilistisch repräsentiert [Bey07],
- Relationen werden als binäre Variablen [Ghe10a] und analog zu Attributen [Ghe10b, Hei10] behandelt.

Mit diesen Aussagen wird insgesamt beschrieben, dass Relationen einerseits ebenfalls probabilistisch repräsentierte Attribute besitzen und andererseits die Existenz einer konkreten Beziehung zwischen zwei Entitäten auch als unsicher betrachtet und über eine binäre Variable repräsentiert wird. Diese Variable kann dabei durch ein Attribut dargestellt werden.



(a) Probabilistisches Attribut für eine Anzahl.



(b) Probabilistisches Attribut für eine Existenzvariable.

Abbildung 4.5: Beispiel für die Darstellung eines probabilistischen Attributs in der Metamodellierung für die adaptive Umweltmodellierung. Als Qualitäten werden eine Anzahl (a) und Existenzvariable (b) repräsentiert. Gelbe Ellipsen stellen dabei Konzepte dar, rote Rechtecke Instanzen.

Aus der Notwendigkeit heraus, dass probabilistische Relationen in der objektorientierten Umweltmodellierung über Attribute verfügen müssen, ergeben sich Konsequenzen für die formale Darstellung solcher Relationen in einer Wissensrepräsentationssprache. So können in OWL z. B. nicht direkt Attribute für Beziehungen dargestellt werden. Weiterhin können auch nur binäre Beziehungen, d. h. Beziehungen zwischen maximal zwei Entitäten, repräsentiert werden. Eine Möglichkeit, mit diesen Einschränkungen umzugehen, besteht in der Reifikation¹ von Relationen, d. h. ihrer Darstellung (in OWL) als ein Konzept. Diesem Konzept können dann, wie benötigt, probabilistische Attribute zugeordnet werden.

Über diese Aussagen hinaus werden in dieser Arbeit die folgenden Betrachtungen zugrunde gelegt. In einem Domänenmodell der objektorientierten Umweltmodellierung dient die Festlegung von probabilistischen Relationen zwei unterschiedlichen Zwecken. Im ersten Fall soll eine Terminologie spezifiziert werden, unter Verwendung derer im Weltmodell dann die konkreten, z. B. aufgrund von Beobachtungen inferierten Beziehungen zwischen Entitäten beschrieben werden können. Zum zweiten dienen Relationen, gleich ob deterministischer oder probabilistischer Natur, der Modellierung von Vorwissen über die Entitäten einer Domäne. In beiden Fällen können domänenunabhängige Aspekte bzgl. der Repräsentation von probabilistischen Relationen bereits in der Metamodellierung festgelegt werden, z. B. was die Unterscheidung unterschiedlicher Arten von probabilistischen Relationen angeht. Die beiden dargelegten Fälle unterscheiden sich in einem wesentlichen Aspekt bzgl. der Wissensrepräsentation: im ersten Fall, der Repräsentation von konkreten Beziehungen z. B. zwischen Objekten einer betrachteten Umgebung, werden Relationen zwischen Instanzen beschrieben. Konkret betrifft dieser Fall Beziehungen zwischen Repräsentanten in der Weltmodell-Komponente. Im zweiten Fall, der Modellierung von Vorwissen, müssen Beziehungen dargestellt werden, die zwischen Typen von Entitäten gelten, repräsentiert durch die Konzepte des Hintergrundwissens. Hier sind also keine Instanzen betroffen, sondern es wird allgemeines Wissen repräsentiert

¹ Vergegenständlichung, von lateinisch „res“, die Sache, und „facere“, machen

in Form von Restriktionen an Konzepte. Ein Metamodell für das Hintergrundwissen der objektorientierten Umweltmodellierung muss die Darstellung beider Arten von Relationen berücksichtigen und ermöglichen.

Arten von relationsbezogenen Unsicherheiten In der Literatur z. B. zu logisch-probabilistischen Repräsentationssprachen (vgl. Abschnitt 2.2.4) werden verschiedene Arten von Unsicherheiten unterschieden. Unsicherheiten, die die Beziehungen zwischen Entitäten betreffen, werden dabei als strukturelle Unsicherheiten bezeichnet [Kol98]. Diese Benennung liegt darin begründet, dass die gegebenen Beziehungen die Struktur eines probabilistisch graphischen Modells bestimmen. Innerhalb der strukturellen Unsicherheiten können folgende Typen unterschieden werden [Kol98, How09]:

- Die *Existenz-Unsicherheit* beschreibt für Relationen die Frage, ob und mit welcher Wahrscheinlichkeit eine Beziehung zwischen zwei Entitäten tatsächlich existiert. Sie deckt sich ihrer Art nach mit der in der objektorientierten Umweltmodellierung postulierten Existenzwahrscheinlichkeit für probabilistische Relationen.
- Die *Anzahl-Unsicherheit* beschreibt Unsicherheit bzgl. der Frage, mit wie vielen anderen Entitäten (eines gegebenen Typs) eine bestimmte Entität in Beziehung steht.
- Die *Referenz-Unsicherheit* beschreibt schließlich die Frage, mit welcher Wahrscheinlichkeit eine Entität mit den Entitäten einer gegebenen Menge in Beziehung steht.

In dieser Arbeit werden alle drei Arten von strukturellen Unsicherheiten für die objektorientierte Umweltmodellierung als relevant betrachtet. Existenz-Unsicherheit betrifft sowohl konkrete Beziehungen im Weltmodell als auch Vorwissen ausdrückende Beziehungen im Hintergrundwissen. Die entsprechende Unsicherheit kann mittels einer binären Zufallsvariablen im Sinne einer Existenzwahrscheinlichkeit dargestellt werden. Anzahl-Unsicherheit wird in dieser Arbeit nur in Bezug auf Vorwissen betrachtet, da bei dieser Art der strukturellen Unsicherheit keine konkreten Instanzen angegeben werden. Die entsprechende Unsicherheit kann mittels einer diskreten

Zufallsvariablen auf absolutem Skalenniveau dargestellt werden, z. B. über den natürlichen Zahlen als Wertebereich.

Referenz-Unsicherheit betrifft wiederum konkrete Instanzen und wird in dieser Arbeit nur in Bezug auf das Weltmodell betrachtet. Die entsprechende Unsicherheit kann mittels einer diskreten Zufallsvariablen über einer gegebenen Menge von Instanzen und auf nominalem Skalenniveau dargestellt werden. Eine gewisse Art von Referenz-Unsicherheit in Bezug auf Konzepte im Hintergrundwissen kann durch die mehrmalige Modellierung einer probabilistischen Relation für das gleiche Ausgangskonzept zu unterschiedlichen Zielkonzepten modelliert werden – vorausgesetzt, dies stellt für den betroffenen Typ von Relation eine semantisch sinnvolle Aussage dar. So kann, als Beispiel aus der Haushaltsdomäne, eine probabilistische Enthaltenseins-Relation zwischen einem Konzept Messer und einem Konzept Schublade modelliert werden, um auszudrücken, dass sich mit spezifizierter Wahrscheinlichkeit eine Instanz des Konzepts Messer in einer Instanz des Konzept Schublade befindet. Zugleich kann über eine weitere probabilistische Enthaltenseins-Relation mit dem Ausgangskonzept Messer modelliert werden, dass sich eine Messer-Instanz mit gegebener Wahrscheinlichkeit in einer Spülmaschinen-Instanz befinden kann. Auf diese Weise lässt sich eine Art der Referenz-Unsicherheit auf der Ebene von Konzepten modellieren. Da jeweils keine konkreten Instanzen betroffen sind, muss sich durch die modellierten Wahrscheinlichkeiten für das Ausgangskonzept bzgl. der Relation nicht notwendigerweise eine normierte Wahrscheinlichkeitsverteilung ergeben.

Arten von probabilistischen Relationen Für die objektorientierte Umweltmodellierung werden daher die in Abbildung 4.6 dargestellten Arten von probabilistischen Relationen unterschieden. Jede Art referenziert dabei verschiedene probabilistische Attribute zu unterschiedlichen Qualitäten. In dieser Arbeit werden probabilistische Relationen reifiziert als Konzept modelliert, um ihnen Attribute zuzuordnen zu können. Das Basiskonzept für probabilistische Relationen definiert dabei zunächst eine Existenzwahrscheinlichkeit als binäres Attribut. Weiterhin besitzt jede probabilistische Relation ein Ausgangselement (Konzept oder Instanz), für welches die Relation

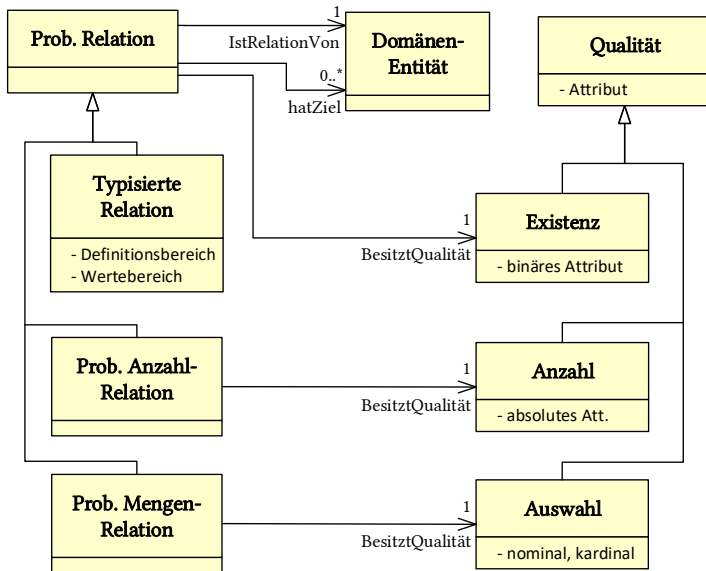


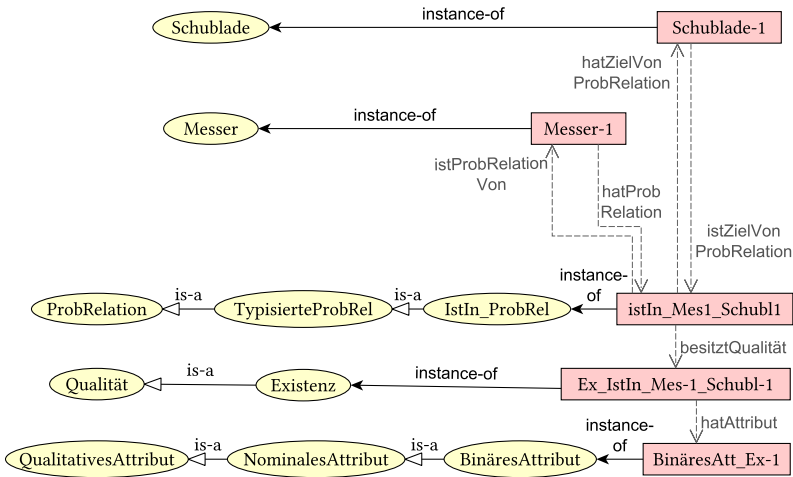
Abbildung 4.6: Detaillierte Modellierung von probabilistischen Relationen (Beziehungen in UML Notation mit Multiplizitäten angegeben).

gilt, sowie ein Zielelement. Zur Darstellung von Anzahl-Unsicherheit wird das Basiskonzept erweitert durch ein Konzept für probabilistische Anzahl-Relationen. Anzahl-Relationen definieren ein probabilistisches Attribut für die Qualität Anzahl. Zur Darstellung von Referenz-Unsicherheit wird ebenfalls das Basiskonzept erweitert, und zwar durch ein Konzept für probabilistische Mengenrelationen. Diese werden über ein Attribut der Qualität Auswahl beschrieben. Eine Auswahl stellt dabei abstrakt eine Enumeration von verschiedenen Symbolen dar, wobei diese Symbole z. B. Instanzen, also Repräsentanten im Weltmodell, referenzieren können. Probabilistisch wird diese Auswahl über ein entsprechendes qualitatives Attribut beschrieben. Die Symbole können weiterhin auch Konzepte referenzieren. Auf diese Weise kann eine probabilistische Typzuordnung von Repräsentanten zu Konzepten im Hintergrundwissen repräsentiert werden (vgl. Kapitel 6).

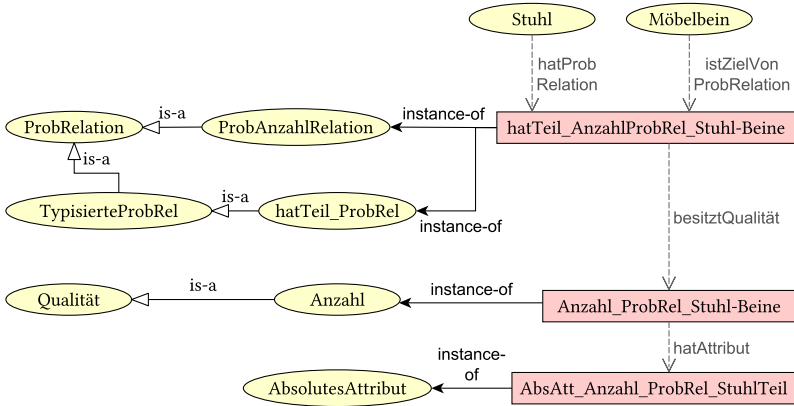
Typen von Relationen Neben diesen Arten von probabilistischen Relationen müssen weiterhin, quasi orthogonal zu den Arten, verschiedene Typen von Beziehungen unterschieden werden, welche probabilistisch repräsentiert werden sollen. Zu diesem Zweck wird ein Konzept für typisierte probabilistische Relationen definiert, unter welchem dann die konkreten Typen von Beziehungen z. B. für eine Anwendungsdomäne einzuordnen sind. Für jeden Typ von Beziehung kann dabei auch der zulässige Definitions- und Wertebereich angegeben werden. Weiterhin kann pro Typ einer Relation auch ein spezifischer Alterungsfaktor für die probabilistische Informationsverarbeitung angegeben werden, welcher das Absinken der Existenzwahrscheinlichkeit von Instanzen dieses Relationstyps über der Zeit beschreibt.

In Abbildung 4.7 sind zwei Beispiele für probabilistische Relationen dargestellt. Diese ergeben sich anhand der gewählten Metamodellierung ebenfalls als semantische Netze. Gelbe Ellipsen stellen dabei wieder Konzepte dar und rote Rechtecke Instanzen. In Abbildung 4.7a wird eine probabilistische Basisrelation gezeigt vom Typ „IstIn“, also eine Enthaltenseins-Relation. Die gezeigte Relation könnte so z. B. zwischen Repräsentanten in der Weltmodell-Komponente bestehen. Als probabilistische Relation besitzt die Relation eine Qualität Existenz mit einem binären Attribut. Ausgangselement der Relation ist eine Instanz des Konzepts Messer, Ziel ist eine Instanz des Konzepts Schublade. In Abbildung 4.7b wird eine probabilistische Relation vom Typ „hatTeil“ gezeigt, also eine Teile-Ganzes-Beziehung. Die Relation ist der Art ihrer Unsicherheit nach eine probabilistische Anzahlrelation und könnte in der gezeigten Form als ein Teil eines Hintergrundwissensmodells dienen. Als Ausgangselement wird das Konzept Stuhl mit dem Ziel-Konzept Möbelbein in Beziehung gesetzt. Die Qualität Anzahl beschreibt dabei über ihr absolutes Attribut wie wahrscheinlich es a priori ist, dass ein Stuhl eine bestimmte Anzahl von Beinen als Teile besitzt.

Szenarmodus von Relationen Neben Qualitäten lassen sich auch Relationen bzgl. der Art ihrer Verwendung in einem Anwendungsfall unterscheiden. Zu diesem Zweck können die für Qualitäten definierten Szenarmodi verwendet werden. Diese lassen sich dabei auf die zuvor genannten Zwecke von Relationen abbilden.



(a) Probabilistische Relation vom Typ „IstIn“ mit Existenzvariable.



(b) Probabilistische Anzahl-Relation vom Typ „hatTeil“.

Abbildung 4.7: Beispiel für die Darstellung von probabilistischen Relationen in der adaptiven Umweltmodellierung. Es wird eine probabilistische Relation mit Existenzwahrscheinlichkeit (a) sowie eine probabilistische Anzahlrelation (b) gezeigt. Gelbe Ellipsen stellen dabei Konzepte dar, rote Rechtecke Instanzen. Die probabilistischen Attribute werden der Übersicht halber verkürzt als Knoten und nicht als semantische Netze dargestellt (die Netze entsprechen ihrer Art nach den in Abbildung 4.5 gezeigten).

Relationen mit semantischem Szenarmodus (kurz: semantische Relationen) dienen im Anwendungsfall zur Modellierung von Vorwissen im Hintergrundwissensmodell. Derartige Relationen können i. A. nicht oder nur bedingt aus Informationen im Weltmodell abgeleitet werden. Perzeptive und deduktive Relationen beschreiben dagegen konkrete Beziehungen zwischen Repräsentanten im Weltmodell. Dabei sind Relationen häufig deduktiv. Dies bedeutet, dass über ihr Vorliegen aufgrund der Attribute von Repräsentanten entschieden wird. Relationen mit unterschiedlichem Szenarmodus erfordern eine unterschiedliche Behandlung in der Informationsverwaltung. Um diese Unterscheidung zu ermöglichen, können im Hintergrundwissen Konzepte für typisierte Relationen entsprechend mit ihrem Szenarmodus annotiert werden. Auf die Szenarmodi von Relationen wird weiterhin in Abschnitt 5.3.4 eingegangen in Verbindung mit der Erzeugung von Relationen in der Informationsverwaltung.

4.4 Strukturierung der Konzepte des Hintergrundwissens

Das objektorientierte Umweltmodell kann in unterschiedlichen Anwendungsdomänen eingesetzt werden. Jede Domäne erfordert ein angepasstes Wissensmodell, welches die für die Domäne relevanten Entitäten und Beziehungen sowie deren Bedeutung beschreibt. All diesen Wissensmodellen muss jedoch ein gemeinsamer Satz von Prinzipien zugrunde gelegt werden. Dies ist eine Voraussetzung, um übergeordnete Anteile der objektorientierten Umweltmodellierung, wie die Informationsverwaltung im Weltmodell oder eine adaptive Anpassung des Hintergrundwissens, domänenunabhängig beschreiben zu können. Auch ist Interoperabilität zwischen verschiedenen Domänenmodellen auf semantischer Ebene erforderlich. Zu einem gewissen Anteil kann dies durch die Vorgaben eines Metamodells erreicht werden. Im in Kapitel 4.3 vorgestellten Metamodell werden allerdings bisher nur spezifische Fragestellungen der objektorientierten Umweltmodellierung betrachtet. Zu allgemeinen Fragestellungen der Wissensmodellierung und formalen Ontologie werden dort keine Festlegungen

getroffen. Eine solche, sehr relevante Fragestellung betrifft die grundlegende kategorische Strukturierung, unter welcher die Welt und mit ihr die zu modellierenden Domänen betrachtet und repräsentiert werden.

Eine solche Strukturierung wird in Top-Level Ontologien festgelegt, welche dazu entsprechende Kategorien als Konzepte definieren. Domänenmodelle, die eine solche Strukturierung respektieren wollen, können dann als eine Erweiterung dieser Top-Level Ontologie erstellt werden. Erfolgt die Definition einer Top-Level Ontologie mit einer entsprechend ausdrucksstarken Axiomatisierung, so kann ein hoher Grad an Interoperabilität zwischen unterschiedlichen, als Erweiterungen dieser Ontologie erstellten Domänenmodellen erreicht werden. Diesem grundsätzlichen Ansatz folgend wird in dieser Arbeit die Ontologie DOLCE [Mas03] als Top-Level Ontologie zur kategorischen Strukturierung von Vorwissen für Domänenmodelle der objektorientierten Umweltmodellierung eingesetzt.

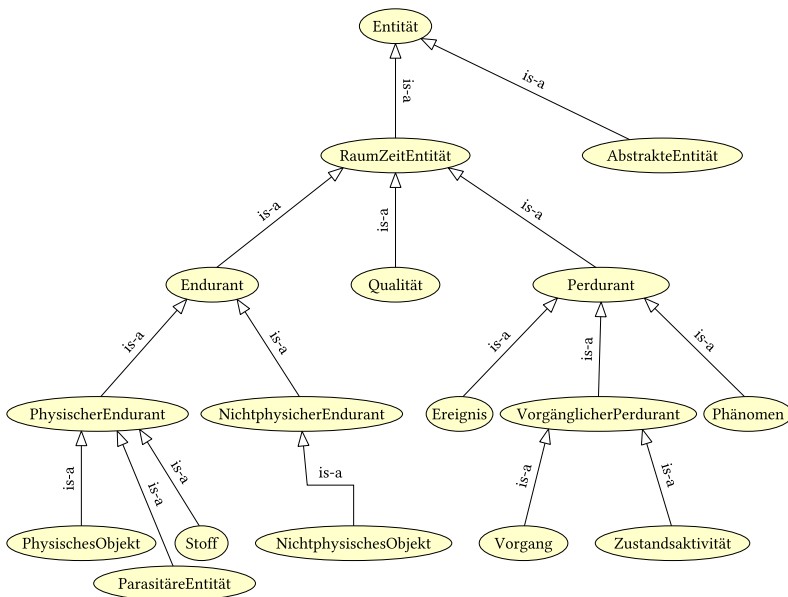


Abbildung 4.8: Grundlegende Strukturierung von Kategorien in der Top-Level Ontologie DOLCE [Mas03] in der Version von DOLCE Lite.

4.4.1 Wissensstrukturierung in DOLCE

DOLCE wurde als eine beschreibende Ontologie entwickelt, welche sich in ihrer grundlegenden Art, wie sie die Welt betrachtet, an der menschlichen Sprache und Kognition orientiert [Mas03]. Für die entwickelte Strukturierung von Wissen spiegelt sich dies in grundlegenden Kategorien wider, die sich auf der Ebene der menschlichen Wahrnehmung und des menschlichen Alltagsdenkens wiederfinden. In Bezug auf Erweiterbarkeit ist DOLCE explizit darauf ausgelegt, als Startpunkt für die Entwicklung von Domänen-Ontologien zu dienen [Mas03].

Die grundlegende Taxonomie von Kategorien in DOLCE ist in Abbildung 4.8 dargestellt. Die Abbildung zeigt dabei einen Ausschnitt der Taxonomie mit leichten Anpassungen, wie sie in der OWL-Version DOLCE Lite¹ umgesetzt sind. DOLCE unterscheidet grob zwischen Entitäten mit Raumzeitbezug („RaumZeitEntität“) und abstrakten Entitäten. Abstrakte Entitäten besitzen dabei weder räumliche noch zeitliche Qualitäten. Qualitäten sind selbst als raumzeitliche Entitäten modelliert. Sie stellen dabei Basis-Entitäten dar, die wahrgenommen oder gemessen werden können [Mas03], wie z. B. die Farbe eines Gegenstandes oder dessen Länge. Als weitere raumzeitliche Entitäten werden Enduranten von Perduranten unterschieden.

Entitäten, welche zu jedem Zeitpunkt vollständig existieren, werden dabei als Enduranten bezeichnet. Entitäten, welche hingegen nur in der Zeit bzw. über die Zeit hinweg existieren, also zu jedem einzelnen Zeitpunkt nicht vollständig existieren, werden als Perduranten bezeichnet. Als unterschiedliche Perduranten werden z. B. Ereignisse, Phänomene und verschiedene Arten von Vorgängen modelliert. Für Enduranten wird zwischen physischen und nichtphysischen Enduranten unterschieden. Physische Enduranten sind dabei Objekte (im Sinne von Gegenständen), Mengen von Stoffen (z. B. ein Liter Wasser) und sog. parasitäre Entitäten. Parasitäre Entitäten stellen bestimmte Eigenschaften oder Merkmale von physischen Enduranten dar, wie

¹ <http://www.loa.istc.cnr.it/old/ontologies/DLP3971.zip>
(letzter Abruf: 08.05.2020)

die Kante eines Tisches oder Aussparungen wie die Löcher einer Steckdose. Nichtphysische Enduranten sind Entitäten, die keine direkten physischen Qualitäten besitzen (wie z. B. einen Ortsbezug oder eine Masse). Allerdings benötigen diese Entitäten einen physischen Enduranten als ihren konstituierenden Bestandteil. Nichtphysische Enduranten stellen somit eine Form der Indirektion dar, die es erlaubt, physische Objekte von den Rollen, die sie erfüllen, unterscheiden zu können. So kann z. B. eine soziale Rolle wie Präsident von der menschlichen Person, die diese Rolle erfüllt, unterschieden werden. Für physische sowie nichtphysische Objekte werden weiterhin Agenten, d. h. handelnde Subjekte, von reinen, nicht handelnden Objekten unterschieden. Die Festlegung und Unterscheidung dieser grundlegenden Kategorien in DOLCE basiert insgesamt auf Prinzipien der formalen Ontologie, wie sie z. B. auch in der OntoClean Methodik [Gua02] zur Erstellung von Taxonomien angewendet werden.

Qualitäten Viele der genannten Kategorien in DOLCE lassen sich anhand der Arten von Qualitäten unterscheiden, welche sie besitzen. Qualitäten stellen in DOLCE als raumzeitliche Entitäten einen eigenen Zweig der Taxonomie dar. Dieser Zweig kann in Domänenmodellen erweitert werden. Grundsätzlich werden in DOLCE physische Qualitäten von zeitlichen und abstrakten Qualitäten unterschieden, analog zur Unterscheidung der entsprechenden Kategorien. Jeder Qualität ist dabei ein Wertebereich, eine sog. Region zugeordnet, welche als abstrakte Entität modelliert ist. Der Wert der Qualität eines Objektes wird in DOLCE indirekt modelliert: jedes konkrete Objekt besitzt für einen gegebenen Typ von Qualität eine konkrete Ausprägung (z. B. die Länge des Esstisches), welcher ein spezifischer (z. B. numerischer) Wert innerhalb der Region der Qualität zugeordnet ist. Somit wird eine konkrete Eigenschaft eines Objekts in DOLCE als ein semantisches Netz modelliert. Abbildung 4.9 zeigt ein Beispiel dafür, wie diesem Ansatz folgend eine Eigenschaft eines Objekts (deterministisch) in einer Wissensbasis beschrieben werden kann. Eine Entität steht dabei über Relationen mit denjenigen Qualitäten in Beziehung, welche sie aufweist. Die Qualitäten stehen wiederum mit ihren Regionen in Beziehung, welche die möglichen Werte der Qualität enthält und eine spezifische Strukturierung aufweisen kann [Mas03]. Eine

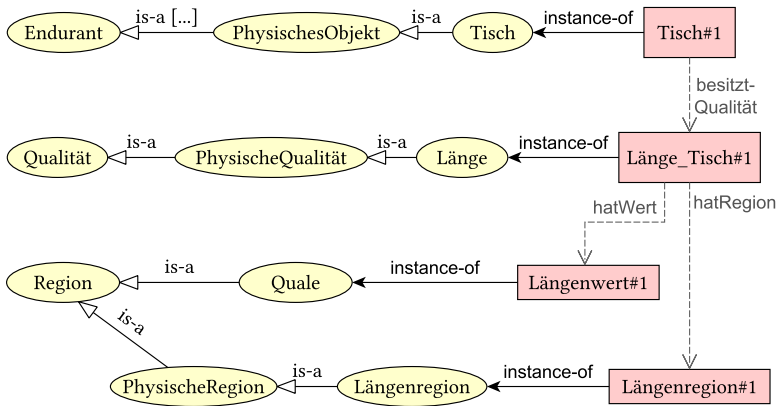


Abbildung 4.9: Darstellung der Eigenschaften von Objekten in DOLCE. Konkrete Eigenschaften werden dabei in Form von semantischen Netzen repräsentiert. Gelbe Ellipsen stellen in der Abbildung Konzepte dar, während rote Rechtecke deren Instanzen repräsentieren.

Qualität steht weiterhin mit sog. *Qualia*¹ in Beziehung, über welche der konkrete Wert einer Qualität als eine atomare Position innerhalb der Qualitätsregion beschrieben wird.

4.4.2 Integration des Metamodells in DOLCE

Die grundlegende Taxonomie der Top-Level Ontologie DOLCE wird in dieser Arbeit zur Strukturierung von Hintergrundwissensmodellen der objektorientierten Umweltmodellierung genutzt. Um dies praktisch zu ermöglichen, muss das in Abschnitt 4.3 vorgestellte Metamodell in DOLCE integriert werden. Zu diesem Zweck wurde das Metamodell formal in OWL modelliert und in DOLCE Lite, der OWL-Version von DOLCE, integriert².

¹ Singular: Quale

² Es lassen sich nicht alle Axiome von DOLCE in OWL DL ausdrücken, daher stellt die OWL-Variante eine „Lite“-Version von DOLCE dar. Diese wird beschrieben und bereitgestellt unter: <http://www.loa.istc.cnr.it/dolce/overview.html> (letzter Abruf: 08.05.2020).

Als Ergebnis wurde eine Kern-Ontologie für die objektorientierte Umweltmodellierung geschaffen, die in OWL 2 DL als Repräsentationssprache dargestellt ist. Die Integration des Metamodells betrifft dabei im Wesentlichen zwei Aspekte: einerseits muss die Darstellung von probabilistischen Attributen ermöglicht werden, andererseits die Repräsentation von probabilistischen Relationen.

Probabilistische Attribute Für die Integration von probabilistischen Attributen müssen zusätzliche Konzepte des Metamodells in DOLCE definiert werden, welche zur Darstellung von unsicherheitsbehafteten Informationen sowie zur Darstellung der Eigenschaften von Qualitäten notwendig sind. Das Konzept Qualität kommt an sich sowohl im Metamodell als auch in DOLCE vor. Die Darstellung des Konzepts im Metamodell ist dabei kompatibel zur DOLCE Kategorie für Qualitäten, so dass keine Anpassung notwendig ist. Auf der Ebene eines Domänenmodells modellierte Qualitäten können somit direkt unterhalb der DOLCE Kategorie für Qualitäten eingehängt werden.

Die weiteren notwendigen Konzepte zur Modellierung von probabilistischen Attributen werden als abstrakte Entitäten in DOLCE eingebunden. Dies betrifft die unterschiedlichen Arten von Attributen, die unterschiedlichen Typen von Wahrscheinlichkeitsverteilungen sowie Konzepte, die zur Darstellung von Wertebereichen notwendig sind. Zur Modellierung der im Metamodell definierten Eigenschaften von Qualitäten werden Konzepte zur Repräsentation der unterschiedlichen Szenar Modi einer Qualität und zur Darstellung von Skalenniveaus jeweils als abstrakte Entitäten definiert.

Weiterhin müssen auch die Beziehungen integriert werden, welche für eine Repräsentation von probabilistischen Attributen als semantische Netze notwendig sind, um die eben genannten Konzepte in Beziehung zu setzen. Zu diesem Zweck werden die benötigten Typen von Relationen als OWL Objektbeziehungen¹ modelliert. Dies betrifft z. B. die Relationen zwischen einem konkreten Attribut und seiner Wahrscheinlichkeitsverteilung oder zur dargestellten Qualität. Einfache Eigenschaften von Qualitäten, welche direkt als Zahlenwerte oder Wahrheitswerte repräsentiert werden können, werden

¹ Englisch: object properties

als OWL Dateneigenschaften¹ modelliert. Dies betrifft z. B. Zahlenwerte zur Beschreibung von Wahrscheinlichkeiten oder von Parametern der probabilistischen Informationsverwaltung wie Alterungsfaktoren.

Probabilistische Relationen Das in dieser Arbeit vorgestellte Metamodell berücksichtigt auch probabilistische Relationen. In DOLCE werden solche Relationen nicht per se unterstützt. Für die Integration von probabilistischen Relationen in die Kern-Ontologie müssen daher ebenfalls zusätzliche Konzepte und Objektbeziehungen definiert werden. Die zusätzlichen Konzepte betreffen dabei die Darstellung der unterschiedlichen Arten von probabilistischen Relationen sowie von typisierten Relationen. Diese werden in dieser Arbeit als raumzeitliche Entitäten in die DOLCE Taxonomie eingeordnet, da probabilistische Relationen potenziell Attribute für räumliche sowie zeitliche Qualitäten besitzen können. Die bereits im Metamodell festgelegten Unterklassen-Beziehungen zwischen diesen zusätzlichen Konzepten werden beibehalten. Analog zum Vorgehen bei probabilistischen Attributen werden in dieser Arbeit die Beziehungen zwischen diesen Konzepten, die zur Darstellung probabilistischer Relationen zusätzlich notwendig sind, als OWL Objektbeziehungen modelliert. Typspezifische Alterungsfaktoren für probabilistische Relationen können unter Verwendung der bereits für Attribute definierten Dateneigenschaft angegeben werden.

Maßeinheiten Auch die zusätzlich notwendigen Konzepte zur Darstellung von Maßeinheiten für probabilistische Attribute werden als abstrakte Entitäten modelliert. Ebenfalls werden die im Metamodell definierten Beziehungen zu Basis-Einheiten als Objektbeziehungen und die benötigten Informationen für eine Konvertierung zwischen unterschiedlichen Einheiten als Dateneigenschaften modelliert. In der Kern-Ontologie der objektorientierten Umweltmodellierung selbst werden dabei nur wenige konkrete Einheiten modelliert, z. B. Längeneinheiten. Auf der Ebene eines Domänenmodells können dann weitere konkrete Einheiten für die Qualitäten eines Anwendungsfalls modelliert werden. Die Einheiten werden, analog zum Vorgehen bei der Definition domänenspezifischer Qualitäten, in einem eigenen Zweig

¹ Englisch: data properties

der Taxonomie dargestellt. In diesem Zusammenhang ist auch die grundsätzliche Erweiterbarkeit der Kern-Ontologie bezüglich Maßeinheiten von Relevanz. Allgemein ist eine Anbindung oder zumindest eine teilweise Verwendung von existierenden Ontologien für Einheiten empfehlenswert. Ein Beispiel für eine solche Ontologie ist die in Abschnitt 2.3.2 genannte Ontologie für Maßeinheiten [Rij13]. Um eine solche Einbindung realisieren zu können, kann zunächst die Ausrichtung¹ oder Abbildung² des einzubindenden Modells auf die Kern-Ontologie der Umweltmodellierung notwendig sein. So ist z. B. die genannte Ontologie für Maßeinheiten bisher nicht direkt mit der Top-Level Ontologie DOLCE kompatibel, vor allem in Bezug auf die Modellierung von Qualitäten [Rij13]. Eine Übernahme relevanter Informationen zumindest in Bezug auf die modellierten Einheiten und ihrer Konvertierungsfaktoren in ein Domänenmodell für die objektorientierte Umweltmodellierung sollte aber dennoch prinzipiell möglich sein. Eine weitere Untersuchung dieses Aspekts liegt allerdings außerhalb des Rahmens dieser Arbeit. Alternativ können existierende Modelle auch genutzt werden, um erfasste Größen zu beobachteten Objekten vorab, d. h. vor dem Einspeisen in das objektorientierte Umweltmodell, in unterstützte Einheiten umzurechnen.

4.4.3 Kern-Ontologie für die objektorientierte Umweltmodellierung

Durch die formale Darstellung des definierten Metamodells in OWL und dessen Integration unterhalb der Top-Level Ontologie DOLCE konnte eine Kern-Ontologie für die objektorientierte Umweltmodellierung erstellt werden. Diese Ontologie soll als Ausgangspunkt dienen, um spezifische Modelle für entsprechende Domänen und Anwendungsfälle der objektorientierten Umweltmodellierung zu definieren. Ein Vorgehen zur Erstellung solcher Domänenmodelle wird in Abschnitt 4.5 diskutiert. Neben den bisher genannten,

¹ Englisch: alignment

² Englisch: mapping

zumeist aus der Metamodellierung resultierenden Eigenschaften der Kern-Ontologie zeichnet sich diese noch durch weitere Eigenschaften aus, die sich zum Teil aus der Verwendung von DOLCE als Top-Level Ontologie ergeben. Diese sollen nachfolgend betrachtet werden.

Definierte Relationen Neben einer Taxonomie von Kategorien werden in DOLCE ebenfalls grundlegende Typen von Beziehungen definiert und als OWL Objektbeziehungen modelliert. Diese beinhalten die bereits genannten Beziehungen zwischen Qualitäten und ihren Regionen, sowie Beziehungen zwischen Entitäten und ihren Qualitäten. Die entsprechenden Relationen wurden bei der Integration des Metamodells bereits verwendet und, wo notwendig, konsistent um weitere Relationen ergänzt. Zwischen Enduranten und Perduranten definiert DOLCE weiterhin eine Beziehung der Teilnahme. Ein Endurant kann dabei an einem Perduranten, z. B. einem Ereignis, teilnehmen. Für Domänenmodelle der objektorientierten Umweltmodellierung kann dieser Typ von Beziehung genutzt werden, um z. B. die an relevanten Vorgängen beteiligten Objekte anzugeben. Enduranten wie Perduranten können weiterhin auch Teile besitzen. Zu diesem Zweck definiert DOLCE eine Teile-Ganzes-Beziehung. Allerdings können Teile von Enduranten in DOLCE nur weitere Enduranten sein, und Teile von Perduranten nur weitere Perduranten. Neben Teilen können Enduranten wie Perduranten auch Bestandteile haben. Auch hierfür wird in DOLCE eine Beziehung definiert. Im Gegensatz zur Teile-Ganzes-Beziehungen basiert die Bestandteil-Beziehung dabei auf einer ontologischen Schichtung von Entitäten: während ein Tisch z. B. Beine als Teile haben kann, so kann eine Menge Holz einer seiner Bestandteile sein. Schließlich definiert DOLCE auch Beziehungen zwischen nichtphysischen Enduranten und den für ihre Existenz notwendigen physischen Enduranten. Diese können in Domänenmodellen der objektorientierten Umweltmodellierung genutzt werden, um die Beziehungen zwischen Rollen und den sie erfüllenden physischen Objekt darzustellen. Darüber hinaus besitzt DOLCE auch noch weitere, spezielle Typen von Beziehungen, auf die hier aber nicht weiter eingegangen wird.

Darstellung von Zeit Zwei weitere wichtige Aspekte des Kernmodells sind die Darstellung von Zeit sowie die Darstellung von Raum bzw. Orten. DOLCE behandelt Ort und Zeit dabei gleich wie jede andere Qualität: es werden entsprechende Regionen definiert, innerhalb derer konkrete Werte dargestellt werden können [Mas03]. Wie diese Regionen genau strukturiert sind, wird dabei auf der Ebene der Top-Level Ontologie nicht festgelegt. Als Qualitäten werden dabei ein Ortsbezug und ein Zeitbezug modelliert, als Regionen z. B. ein Zeitintervall. In Bezug auf die Darstellung von zeitlichen Aussagen bietet DOLCE in seiner vollen prädikatenlogischen Axiomatisierung die Möglichkeit von zeitindizierten Relationen. Mittels dieser kann ausgedrückt werden, zu welchem Zeitpunkt oder Zeitintervall eine Relation Geltung besitzt.

Für die objektorientierte Umweltmodellierung ist zumindest die Darstellung von Zeitstempeln wichtig. Dies gilt für die probabilistische Informationsverwaltung sowie für eine adaptive Umweltmodellierung. Beispielsweise werden Zeitstempel zur Angabe der Zeitpunkte benötigt, zu welchen ein Objekt in der betrachteten Umgebung sensoruell beobachtet wurde. Auch werden Zeitstempel benötigt um darzustellen, zu welchem Zeitpunkt ein Repräsentant im Weltmodell zuletzt aktualisiert wurde. Falls mittels adaptiver Umweltmodellierung neue Konzepte für das Hintergrundwissen gelernt werden können, so muss ebenfalls durch Zeitstempel markiert werden, wann diese dem Hintergrundwissen hinzugefügt wurden. Die Angabe einfacher Zeitstempel ist in OWL über zwei sprachinterne Konstrukte möglich, welche eine deterministische Darstellung von Zeitstempeln mittels ISO 8601 kompatibler Datentypen ermöglichen. Dieser Mechanismus ist für die genannten internen Zwecke der objektorientierten Umweltmodellierung zunächst ausreichend. Weiterhin ermöglicht die Kern-Ontologie der objektorientierten Umweltmodellierung eine Zeitdauer als Qualität zu modellieren, welche mittels probabilistischer Attribute und in einer modellierten Zeiteinheit auch unsicherheitsbehaftet dargestellt werden kann. Domänenmodelle können somit eine Zeitdauer, wenn benötigt, repräsentieren. Sollen zusätzlich (deterministische) Zeitintervalle in einer gemischten Darstellung in verschiedenen Zeiteinheiten angegeben werden können, so ist die Integration existierender Zeit-Ontologien sinnvoll. Ein guter Kandidat ist hierbei durch OWL-Time

[W3C20] gegeben. Im Rahmen dieser Arbeit wurde dieser Aspekt allerdings nicht genauer betrachtet. Auch weitere zeitliche Relationen, welche symbolische Beziehungen zwischen Zeitintervallen und Zeitpunkten formal darstellen, werden in der Kern-Ontologie nicht betrachtet, da eine Darstellung mittels Zeitstempeln für die probabilistische Informationsverwaltung und adaptive Umweltmodellierung ausreichend ist. Symbolische zeitliche Relationen, welche auch zeitliches Schlussfolgern ermöglichen, können jedoch in entsprechenden Domänenmodellen oder in den der objektorientierten Umweltmodellierung nachgelagerten Komponenten definiert und aufgrund der Zeitstempel des Kernmodells instanziiert werden, falls gewünscht.

Darstellung von Orten Die Darstellung von Orten ist für die objektorientierte Umweltmodellierung aus zwei Gründen wichtig: einerseits für Positionen von konkreten Entitäten, andererseits für die Repräsentation von qualitativem ortsbezogenen Vorwissen für Typen von Entitäten. Positionen müssen z. B. für beobachtete Objekte (Instanzen) angegeben werden. Die Angabe erfolgt metrisch und kann sich, abhängig von Anwendungsfall und -domäne, auf ein lokales bzw. globales geometrisches oder auf ein geographisches Koordinatensystem beziehen. Durch die Festlegung entsprechender Koordinatenreferenzsysteme in einem Domänenmodell können auch unterschiedliche Koordinatensysteme zugleich unterstützt werden [Kuw13c], die Positionsangaben müssen dann entsprechend transformiert werden. Die einzelnen Arten von Koordinaten in einer Positionsangabe können als Qualitäten in Domänenmodellen unter der Qualität Ortsbezug in der Kern-Ontologie eingehängt werden und stellen im Regelfall perzeptive, zustandsbezogene Qualitäten dar.

Zur Repräsentation von qualitativen Ortsangaben werden räumliche Relationen benötigt. In DOLCE wurden bereits einige relevante Beziehungen definiert, darunter eine Teile-Ganzes-Beziehung, eine Verbundenheitsbeziehung und eine Überlappingsbeziehung. Zusätzlich kann die Definition weiterer räumlicher Beziehungen sinnvoll bzw. notwendig sein. Dies kann z. B. die Definition spezifischer Abstands- und Richtungsbeziehungen betreffen. Ebenfalls kann eine Enthaltenseins-Beziehung betroffen sein, welche modelliert, dass sich ein Objekt innerhalb eines anderen Objekts befindet, ohne

ein Teil von diesem zu sein. Unter Verwendung dieser Beziehungen können ebenfalls Ortsangaben für konkrete Entitäten beschrieben werden.

Um semantisches ortsbezogenes Vorwissen für Konzepte in einem Hintergrundwissensmodell darzustellen, werden ebenfalls qualitative räumliche Relationen benötigt. Semantisches ortsbezogenes Vorwissen beschreibt dabei i. A. räumliche Beziehungen, die zwischen Typen von Entitäten bestehen, nicht zwischen Instanzen. So kann z.B. beschrieben werden, in welcher räumlichen Anordnung hypothetische Instanzen bestimmter Typen von Entitäten zueinander gegeben sein müssten, damit eine bestimmte Situation vorliegt (wie z. B. ein gedeckter Esstisch, als Beispiel aus der Haushaltsdomäne). Auch soll häufig Vorwissen darüber beschrieben werden, in welchen räumlichen Beziehungen bestimmte Typen von Entitäten grundsätzlich stehen können. Zu diesem Zweck werden räumliche Relationen benötigt, welche eine modale oder zweckgebundene Semantik besitzen. Beispielsweise kann so Vorwissen darüber dargestellt werden, wo hypothetische Instanzen eines bestimmten Typs von Entität wahrscheinlich aufzufinden sind, sollten sie gesucht werden (z. B. wenn Teller zum Decken eines Tisches benötigt werden, um im Beispiel der Haushaltsdomäne zu bleiben), oder wo solche Instanzen z. B. zum Zwecke einer Lagerung aufbewahrt werden.

DOLCE bietet einen passenden Aufsatzpunkt, falls es nötig oder gewünscht sein sollte, bestimmte qualitative räumliche Beziehungen auf der Grundlage von metrischen Positionsangaben zu definieren und somit in einer perzeptiven Qualität zu verankern. Durch ein solches Vorgehen lässt sich die Bedeutung einer räumlichen Relation über deren semantischen, qualitativen Aspekt hinaus durch quantitative Anteile ergänzen. Der Aufsatzpunkt ist durch die Kategorie der parasitären Entitäten in der Taxonomie von DOLCE (und somit auch in der Kern-Ontologie) gegeben. Somit können z. B. das Innere eines hohlen Gegenstandes oder die Oberseite eines Gegenstandes als parasitäre Entitäten modelliert werden. Durch eine solche Modellierung lässt sich dann z. B. eine räumliche Enthaltenseins-Beziehung zwischen hohlen Gegenständen und weiteren Gegenständen über deren Positionen, innere und äußere Abmessungen sowie Formen quantitativ beschreiben. Ähnliches ist

für Richtungsbeziehungen wie „auf“ möglich. Derart in perzeptiven Qualitäten verankerte Relationen können für ein technisch kognitives System zur Ausführung seiner Aufgaben oft nützlicher sein als rein qualitative Relationen. Ob eine solche Verankerung notwendig ist, hängt allerdings wiederum vom betrachteten Anwendungsfall ab. In Abschnitt 5.3.4 wird ein Beispiel dafür gegeben, wie eine probabilistische räumliche Relation vom Typ „nahe bei“ auf Basis der Positionsattribute der beteiligten Repräsentanten definiert werden kann.

Interoperable Bereitstellung von Beobachtungen Die Kern-Ontologie unterstützt nicht nur die Erstellung von interoperablen Domänenmodellen, sondern kann darüber hinaus für eine interoperable Anbindung von unterschiedlichen Sensoren an ein objektorientiertes Umweltmodell genutzt werden. Dies wird ermöglicht durch die formale Repräsentation der Prinzipien des Metamodells. Darüber hinaus wird allerdings auch konkretes Wissen über die zu modellierende Domäne und ggf. Anwendung benötigt, und zwar in Form der auftretenden Qualitäten.

Steht die Taxonomie mit konkret verwendeten Qualitäten auf Ebene eines Anwendungsmodells fest, so kann diese Taxonomie als Wissensartefakt für eine interoperable Erstellung von Beobachtungen genutzt werden [Kuw16]. Dies wird in Abbildung 4.10 illustriert. Beobachtungen bezeichnen hierbei die Datenstrukturen, mittels derer die Messergebnisse für Qualitäten von Domänen-Entitäten durch Sensoren an die Weltmodell-Komponente des objektorientierten Umweltmodells übermittelt werden.

Softwaretechnisch kann das objektorientierte Umweltmodell hierbei als ein Server betrachtet werden, welcher die Qualitäts-Taxonomie als eine eigene Ontologie bereitstellt und somit für angebundene Sensoren verfügbar macht. Einem Sensor wird somit die Menge der definierten Qualitäten für Domänen-Entitäten bekannt gemacht, sowie die Information, auf welche Art gemessene Werte für eine Qualität im Umweltmodell repräsentiert werden, also z. B. in Bezug auf das Skalenniveau und den Wertebereich einer Qualität. Auf dieser Grundlage kann, unter Angabe der gewünschten Qualitäten,

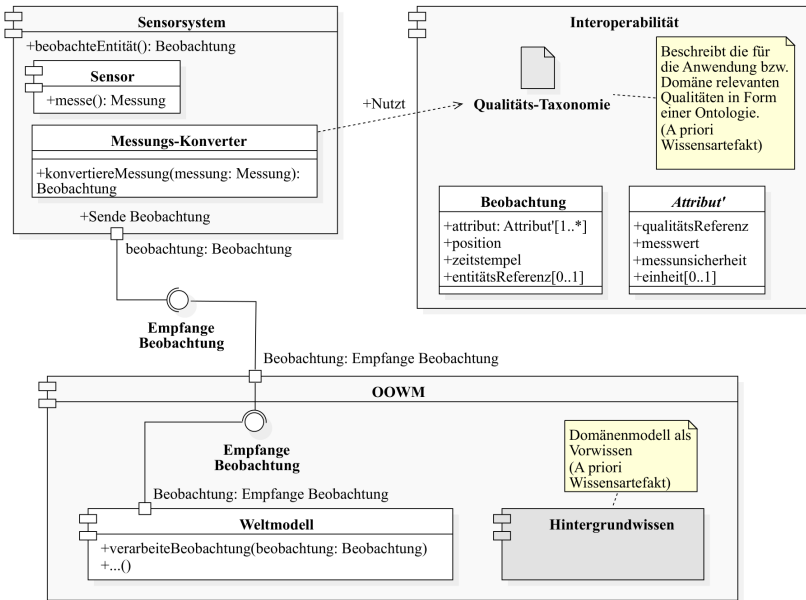


Abbildung 4.10: Interoperabilität und externe Schnittstellen im objektorientierten Umweltmodell OOEM (angepasst aus [Kuw16]). Eine Qualitäts-Taxonomie definiert die beobachtbaren Eigenschaften von Entitäten, welche im Weltmodell repräsentiert werden können. Die Sensordaten, die sich als Ergebnis einer Messung solcher Eigenschaften ergeben, werden zunächst zu Beobachtungen konvertiert und anschließend ans Weltmodell gesendet.

automatisiert eine Beobachtungsdatenstruktur erzeugt werden, welche entsprechende Attribut-Schablonen enthält. Attribut-Schablonen sind in Anlehnung an die Attribute des Metamodells definiert. In sie können die Messergebnisse für die einzelnen Qualitäten eingetragen werden, samt einer Unsicherheit der Messung. Zusätzlich müssen in der Beobachtung noch Metainformationen zur Messung (wie Zeitstempel, Position, ggf. eine Referenz auf eine bereits bekannte Entität etc.) bereitgestellt werden. Die befüllte Beobachtung kann anschließend an das Weltmodell übertragen werden. Durch dieses Vorgehen wird insgesamt eine Entkopplung der konkret eingesetzten Sensorik von den erworbenen Informationen erreicht, welche zugleich die semantische Interoperabilität der Informationen sicherstellt. Dieser Ansatz

stellt unter den Voraussetzungen des objektorientierten Umweltmodells eine Alternative zur direkten Verankerung der symbolischen Repräsentanten des Weltmodells in Sensordaten dar.

Automatisierte Erstellung der Repräsentationsstrukturen Die vorausgehend beschriebene, zum Großteil automatisierte Erstellung einer Beobachtungsdatenstruktur zeigt den Aspekt, dass die zur Repräsentation von probabilistischen Informationen im Kern-Modell benötigten semantischen Netze prinzipiell automatisiert aus einfacheren Darstellungsformen erzeugt werden können. Diese einfacheren Darstellungsformen müssen dabei alle benötigten Informationen enthalten. Diese prinzipielle Möglichkeit einer automatisierten Verarbeitung vereinfacht auch die Weiterverarbeitung von in der Kern-Ontologie repräsentierten Informationen. Eine Weitergabe von Informationen kann dabei z. B. intern im objektorientierten Umweltmodell erfolgen, durch Konvertierungen zwischen verschiedenen Darstellungsformen, oder extern, wenn die Informationen von weiteren Komponenten eines kognitiven Systems abgerufen werden.

4.5 Erstellung von Domänenmodellen zur Kern-Ontologie

Die in dieser Arbeit definierte Kern-Ontologie für die objektorientierte Umweltmodellierung vereinigt die im Metamodell beschriebenen Aspekte mit einer grundlegenden Strukturierung von Wissen durch eine Top-Level Ontologie. Die Kern-Ontologie dient dabei primär als Ausgangspunkt zur Erstellung von domänenspezifischen Modellen. Für ein Hintergrundwissensmodell in der objektorientierten Umweltmodellierung lassen sich somit folgende Ebenen unterscheiden:

- Top-Level Ontologie (DOLCE Lite),
- Kern-Ontologie (Umsetzung und Integration des Metamodells),
- Domänenmodell und
- Anwendungsmodell.

Die Ebenen entsprechen den in der Literatur genannten Schichten zum Aufbau eines geschichteten Ontologie-Modells (vgl. 2.2.3). Alle Schichten werden beim gewählten Vorgehen in OWL 2 DL beschrieben.

Domänen- und Anwendungsmodelle werden als Erweiterungen der Kern-Ontologie erstellt. Dabei müssen die domänenspezifischen Entitäten und Relationen sowie deren Qualitäten modelliert werden. Die Erstellung solcher Modelle kann schrittweise erfolgen. Bei der Vorstellung des Metamodells in Abschnitt 4.3.1 wurde bereits darauf eingegangen, dass die Eigenschaften der in einer Anwendung relevanten Qualitäten schrittweise festgelegt werden können. Zu diesem Zweck dient z. B. die Angabe des maximalen Skalenniveaus einer Qualität. Eine schrittweise Spezifizierung bedeutet, dass auf Ebene eines Domänenmodells Qualitäten zunächst nur abstrakt beschrieben werden, um die derart dargestellten Qualitäten auch für unterschiedliche Anwendungsfälle nutzen zu können. Qualitäten können somit in verschiedenen Anwendungsmodellen unterschiedlich spezialisiert werden. Dies gilt in gleicher Weise natürlich auch für abstrakter beschriebene Domänen-Entitäten. Allerdings können in einer Domäne auch Entitäten relevant sein, die bereits auf der Ebene des Domänenmodells konkreter modelliert werden müssen. In diesem Fall kann bereits hier für einzelne Qualitäten eine konkrete Beschreibung erforderlich sein. Auch kann es sein, dass auf der Ebene des Domänenmodells bereits probabilistische Relationen benötigt werden, um die Beziehung zwischen Typen von Domänen-Entitäten konkret beschreiben zu können. Diese domänenspezifischen Relationen müssen schließlich auf der Ebene des Anwendungsmodells um anwendungsspezifische Relationen ergänzt werden. Hier müssen auch alle anwendungsrelevanten Domänen-Entitäten und deren Qualitäten konkret beschrieben werden. Das Anwendungsmodell legt somit die Terminologie fest, welche dann in der Weltmodell-Komponente des objektorientierten Umweltmodells zur Darstellung des Umgebungszustandes verwendet wird.

Eine weitere Art des schrittweisen Vorgehens, welche als orthogonal zu den Ebenen der Ontologie-Schichtung betrachtet werden kann, betrifft die deterministische gegenüber der probabilistischen Modellierung der Eigenschaften und Beziehungen von Domänen-Entitäten. Dabei kann z. B. zunächst ein

relationales Modell mit deterministischen Attributen und Relationen erstellt werden. Anschließend kann, wo gewünscht oder notwendig, dieses relationale Modell um eine Darstellung von Unsicherheiten erweitert werden, in Form von probabilistischen Attributen und Relationen. Eine derartige Beschreibung erhöht oft die Präzision des modellierten Wissens (eine Tatsache, die sich als Erfahrungswissen auch in der Redewendung „keine Regel ohne Ausnahme“ widerspiegelt). Auf diese beiden Schritte zur Erstellung eines Hintergrundwissensmodells für die objektorientierte Umweltmodellierung wird nachfolgend eingegangen. Zuvor sei noch allgemein angemerkt, dass insgesamt zur Erstellung von Hintergrundwissensmodellen ein strukturiertes Vorgehen angewendet werden sollte, wie in Abschnitt 2.2.3 dargestellt. Die Erstellung der probabilistischen Modellanteile kann dabei z. B. in der Definitionsphase nach der Konzeptualisierung und vor der eigentlichen Formalisierung erfolgen.

4.5.1 Relationale Modellierung

Ähnlich wie die in Abschnitt 2.2.4 vorgestellten logisch-probabilistischen Modellierungssprachen besteht auch ein Hintergrundwissensmodell der objektorientierten Umweltmodellierung aus einem relationalen Anteil und einem probabilistischen Anteil. Der relationale Anteil ergibt sich dabei größtenteils aus dem Einsatz von OWL als Repräsentationssprache sowie aus den bereits in DOLCE definierten Modellelementen. Relational und somit deterministisch werden z. B. taxonomische Zusammenhänge zwischen Konzepten sowie zwischen Relationen modelliert. In DOLCE werden, wie genannt, grundlegende Arten von deterministischen Beziehungen festgelegt, darunter z. B. Teile-Ganzes-Beziehungen und Bestandteil-Beziehungen. Diese Beziehungen sind ebenfalls deterministisch modelliert. Sie können auch in der objektorientierten Umweltmodellierung als Basisbeziehungen genutzt werden. Falls benötigt, können probabilistische Versionen dieser Beziehungen in einer Domänen-Ontologie als typisierte Relationen definiert werden. Weiterhin können auch in Domänen- und Anwendungsmodellen deterministische Attribute und Beziehungen eingeführt werden, falls die Gegebenheiten

der betrachteten Domäne dies erlauben oder erfordern. Deterministische Attribute können dabei als eine abkürzende Schreibweise für probabilistische Attribute mit sicherer Wahrscheinlichkeit aufgefasst werden. Unter Anwendung einer Modelltransformation können solche deterministischen Attribute auch in bedeutungsgleiche probabilistische Attribute überführt werden. Ähnliches gilt für deterministische Beziehungen. Ein Vorteil, der sich durch den relationalen Anteil eines Domänenmodells ergibt, ist die Anwendung von Standard-Verfahren für OWL Reasoning, z. B. zur Konsistenzprüfung des Wissensmodells während der Entwicklung oder für semantische Abfragen von Wissen durch andere Komponenten des kognitiven Systems.

Somit kann es vorteilhaft sein, für ein zu erstellendes Domänenmodell zunächst eine relationale Grundstruktur zu modellieren und zu verifizieren. Auch die Zugreifbarkeit von in dieser Grundstruktur modellierten Informationen durch standardisierte Abfragesprachen wie SPARQL¹ kann von Vorteil sein. Daher sollten auch die probabilistischen Domänenmodelle in der objektorientierten Umweltmodellierung auf einem soliden relationalen Basismodell aufsetzen.

4.5.2 Probabilistische Modellierung einer Domäne

Ein wesentliches Merkmal der objektorientierten Umweltmodellierung ist die konsistente Behandlung von unsicherheitsbehafteten Informationen. Motiviert wird dieses Vorgehen vor allem aus der messtechnischen Sicht heraus, dass die Beobachtungen von Objekten als Messungen auch immer mit einer Messunsicherheit verbunden sind. Beobachtungen werden in der Weltmodell-Komponente des objektorientierten Umweltmodells verarbeitet. Daher wird in Vorarbeiten auch hauptsächlich dort eine probabilistische Informationsverarbeitung und -darstellung betrachtet.

Auch ein Hintergrundwissensmodell muss allerdings grundsätzlich in der Lage sein, mit den unsicherheitsbehaftet dargestellten Repräsentanten des

¹ Abfragesprache des W3C für RDF und OWL, Spezifikation gegeben unter: <https://www.w3.org/TR/rdf-sparql-query/>

Weltmodells umgehen zu können. Dies betrifft z. B. deren Zuordnung zu einem passenden Konzept. Konzepte können dabei ebenfalls in probabilistischer Form beschrieben werden. Darüber hinaus kann eine allgemeine Darstellung von unsicherheitsbehaftetem Vorwissen auch vorteilhaft sein und vermag sogar in einigen Fällen einen Sachverhalt per se präziser auszudrücken als eine deterministische Repräsentation. Andererseits ist die probabilistische Modellierung einer Domäne i. A. aufwendiger als eine rein relationale Modellierung, z. B. in Bezug auf die Anzahl an festzulegenden Parametern (für Wahrscheinlichkeitsverteilungen).

Die probabilistische Modellierung einer Domäne in der objektorientierten Umweltmodellierung stellt somit immer einen Kompromiss dar. Auf der einen Seite steht dabei die notwendige Unterstützung des Weltmodells und die erhöhte Präzision bei der probabilistischen Repräsentation von Vorwissen, auf der anderen Seite steht dagegen der erhöhte manuelle Aufwand der Modellerstellung. Daher soll nachfolgend zunächst die Frage betrachtet werden, für welche Anteile eines Hintergrundwissensmodells eine probabilistische Modellierung nutzbringend oder sogar erforderlich ist. Die Betrachtung und Festlegung erfolgt dabei auf der Ebene von Konzepten, Qualitäten und Relationen. Eine detaillierte Antwort auf diese Frage hängt i. A. vom betrachteten Anwendungsfall ab. Darüber hinaus lassen sich allerdings für die objektorientierte Umweltmodellierung auch allgemeine, d. h. domänenunabhängige Aussagen bzgl. dieser Fragestellung ableiten.

Sobald feststeht, welche Anteile probabilistisch zu modellieren sind, stellt sich die Frage nach dem „Wie“ einer probabilistischen Modellierung, d. h. einem Vorgehen zur Erstellung von entsprechenden probabilistischen Beschreibungen. Diese Fragestellung wird ebenfalls nachfolgend erörtert.

Anwendungszweck der probabilistischen Modellierung für die Umweltmodellierung

Wie in den Anforderungen an die Wissensmodellierung in der objektorientierten Umweltmodellierung beschrieben, dient die probabilistische Modellierung von Konzepten zwei hauptsächlichen Anwendungszwecken: Einerseits soll sie die Klassifikation von probabilistisch beschriebenen Repräsentanten ermöglichen, andererseits das Ableiten von weiteren Informationen über klassifizierte Repräsentanten. Diese Informationen können in Form von semantischen Attributen oder allgemein als Relationen im Wissensmodell gegeben sein. Für die probabilistische Modellierung einer Domäne bedeutet dies, dass zumindest all diejenigen Konzepte, die im Anwendungsfall durch konkrete Objekte der Domäne instanziiert sind, mittels probabilistischer Attribute beschrieben werden sollten. Dies betrifft unmittelbar zunächst einmal nur die Blattkonzepte der „is-a“-Generalisierungshierarchie eines Hintergrundwissensmodells. In Bezug auf die Klassifikation von Repräsentanten sind für diese Blattkonzepte weiterhin nur die Attribute für perzeptive, nicht zustandsbezogene Qualitäten relevant.

Adaptive Umweltmodellierung In einer offenen Welt muss weiterhin die Situation berücksichtigt werden, dass für einen zu klassifizierenden Repräsentanten kein direktes Konzept im Wissensmodell hinterlegt ist, das also keines der Blattkonzepte den Repräsentanten hinreichend gut beschreibt (für eine genauere Betrachtung der Fragestellung, wann eine Beschreibung hinreichend gut ist, sei an dieser Stelle auf Kapitel 6 verwiesen). In diesem Fall kann es von Mehrwert sein, einen Repräsentanten dennoch grob taxonomisch einordnen zu können. Zu diesem Zweck können übergeordnete Konzepte auf den nächsten Ebenen über den Blattkonzepten in der Generalisierungshierarchie verwendet werden, solange diese Konzepte nicht zu abstrakt definiert sind. Die übergeordneten Konzepte sollten dazu zumindest noch ausreichend diskriminative perzeptive Attribute aufweisen (um einen Repräsentanten eindeutig zuweisen zu können) sowie informative semantische Attribute (um nach einer Klassifizierung entsprechend nützliche Informationen ableiten zu können). Wenn, als ein Beispiel aus der später betrachteten Haushaltsdomäne, ein Repräsentant weder als Tafelmesser noch

als Anrichtemesser klassifiziert werden kann, so kann es dennoch nützlich sein, den durch den Repräsentanten dargestellten Gegenstand allgemein als ein Messer identifizieren zu können. Seine Einordnung als ein Werkzeug oder gar als ein Gegenstand, angenommen dies wären die dem Konzept Messer taxonomisch übergeordneten Konzepte, wäre dagegen deutlich weniger informativ. Somit kann es zur Unterstützung der adaptiven Umweltmodellierung angebracht sein, nicht nur die Blattkonzepte, sondern auch die Konzepte der direkt darüber liegenden Ebenen probabilistisch zu modellieren.

Allerdings besteht bei diesem Vorgehen oft die Schwierigkeit, belastbare und zugleich präzise Informationen zur Erstellung der probabilistischen Modelle für die Qualitäten solcher abstrakter Konzepte zu erwerben. Besonders in dem Fall, dass nicht alle möglichen untergeordneten Konzepte tatsächlich ausmodelliert werden sollen, kann dieses Vorgehen dennoch nützlich bzw. notwendig sein. Alternativ zu einer manuellen probabilistischen Modellierung der Konzepte ist auch ein automatisiertes Vorgehen möglich. In diesem Fall werden die probabilistischen Attribute eines übergeordneten Konzepts aus den probabilistischen Attributen aller untergeordneten Konzepte rekursiv durch Zusammenfassung und Generalisierung automatisiert abgeleitet. Verfahren, die dafür eingesetzt werden könnten, werden z. B. in Kapitel 8.4 beschrieben.

Bisher wurde die Frage nach einer probabilistischen Modellierung nur für perzeptive Attribute betrachtet. Die Betrachtung konnte dabei domänenunabhängig durchgeführt werden. Ob für semantische und deduktive Attribute eine probabilistische Modellierung ebenfalls notwendig ist oder ob ein deterministisches Modell ausreicht, kann von Anwendungsfall zu Anwendungsfall entschieden werden. Weiterhin kann es ein Anwendungsfall auch erfordern, zusätzlich zu den bisher genannten Konzepten noch weitere Konzepte mittels probabilistischer Attribute darzustellen, z. B. wenn eine deterministische Beschreibung zu unpräzise wäre.

Vorgehen für die probabilistische Modellierung

Als probabilistische Modelle sind im Hintergrundwissen des objektorientierten Umweltmodells die Wahrscheinlichkeitsverteilungen für die probabilistischen Attribute relevanter Typen von Entitäten und Relationen zu modellieren. Die modellierten Wahrscheinlichkeiten werden in der objektorientierten Umweltmodellierung dabei als Bayes'sche Wahrscheinlichkeiten im Sinne eines Grades des Dafürhaltens interpretiert. Als A-priori-Verteilungen stellen sie somit unsicherheitsbehaftetes Vorwissen für die Qualitäten der betrachteten Entitäten und Relationen bereit.

Definition von A-priori-Verteilungen Die Frage, unter welchem Vorgehen Vorwissen in Form von A-priori-Verteilungen modelliert werden sollte, kann als eine eigene Forschungsfrage innerhalb der Bayes'schen Statistik betrachtet werden. Grundsätzlich lassen sich zwei verschiedene Arten von Vorgehen unterscheiden, welche als subjektiv bzw. objektiv bezeichnet werden [Jay68]. Bei einem subjektiven Vorgehen ergibt sich die modellierte A-priori-Verteilung anhand der persönlichen Vorstellung eines Experten, basierend auf seinem entsprechenden Vorwissen. Für verschiedene Experten können sich dabei auch bei gleichem Vorwissen unterschiedliche A-priori-Verteilungen ergeben. Dieser Aspekt wird aus Sicht eines objektiven Vorgehens kritisiert. Objektive Vorgehen stellen dabei Prinzipien in den Vordergrund, mittels derer sich A-priori-Verteilungen ausgehend von einem gegebenen Vorwissen methodisch und somit objektiv ableiten lassen. Dies betrifft z. B. das Indifferenzprinzip nach Laplace oder das Prinzip der maximalen Entropie nach Jaynes [Jay68]. Bei letzterem wird aus einer gegebenen Klasse von zulässigen Wahrscheinlichkeitsverteilungen diejenige Verteilung ausgewählt, welche die größte Entropie besitzt (im Sinne der Shannon'schen Informationstheorie). Je größer die Entropie, desto weniger Information ist in einer Verteilung enthalten. Das Prinzip der maximalen Entropie zielt nun daraufhin ab, außer den notwendigen Bedingungen so wenig wie möglich zusätzliche Informationen in einer Verteilung darzustellen, da solche zusätzliche Informationen nicht objektiv begründbar sind. Die notwendigen Bedingungen beschreiben dabei die Klasse der zulässigen Verteilungen, aus denen

die optimale Verteilung ausgewählt wird, und können z. B. als Bedingungen an die Momente von Verteilungen formuliert sein.

A-priori-Verteilungen in der Umweltmodellierung In der objektorientierten Umweltmodellierung soll in einem Hintergrundwissensmodell Vorwissen über eine Anwendungsdomäne repräsentiert werden. Solches Vorwissen kann dabei von Domänenexperten bereitgestellt werden. Für die A-priori-Verteilungen der Attribute probabilistisch modellierter Typen von Entitäten bedeutet dies, dass sie dabei unter Anwendung eines subjektiven Vorgehens erzeugt werden. Sind für die Werte von Attributen Einschränkungen bekannt, mittels derer sich entsprechende Bedingungen an die möglichen Wahrscheinlichkeitsverteilungen der Attribute beschreiben lassen, so kann auch ein objektives Vorgehen zur Erstellung der A-priori-Verteilungen eingesetzt werden, z. B. die Methode der maximalen Entropie. Häufig sind die für eine Anwendungsdomäne der objektorientierten Umweltmodellierung zu modellierenden Informationen allerdings nicht derart formalisierbar, dass entsprechende Bedingungen abgeleitet werden könnten, welche z. B. Momente der Verteilung charakterisieren. Zumindest geht dies häufig nicht in einer Form, die zur objektiven Erzeugung von ausreichend informativen A-priori-Verteilung benötigt werden würde. Einschränkungen von Wertebereichen auf z. B. Nichtnegativität sind dagegen möglich. Einen Kompromiss zwischen subjektiver und objektiver Modellierung stellt eine Modellierung der A-priori-Verteilungen auf Basis einer statistischen Analyse entsprechender Attributwerte dar. Dieser Ansatz ist auch für die Anwendungsdomänen der objektorientierten Umweltmodellierung relevant.

Pragmatische Aspekte Neben den wissenschaftstheoretischen Aspekten bezüglich der Erzeugung einer A-priori-Verteilung spielen für das objektorientierte Umweltmodell als eine Softwarekomponente auch noch weitere Aspekte eine Rolle. Diese Aspekte beinhalten die Art der Repräsentation einer A-priori-Verteilung sowie ihre effiziente Weiterverarbeitbarkeit z. B. im Rahmen der probabilistischen Informationsverarbeitung. Entsprechende Anforderungen aus Sicht des objektorientierten Umweltmodells, um eine effiziente Verarbeitung sicherzustellen, bestehen hierbei in einer parametrischen Repräsentation der Verteilung, d. h. für stetige Merkmal z. B.

in Form von Normalverteilungen oder Gaußmischverteilungen. Zu Anfang dieses Kapitels wurden stochastische Unabhängigkeitsannahmen für Hintergrundwissensmodelle der objektorientierten Umweltmodellierung formuliert. Aufgrund dieser Annahmen kann jedes Attribut einer Entität i. A. für sich, also unabhängig von den anderen Attributen, stochastisch modelliert werden.

Stichproben-basierte Definition von Verteilungen Einen pragmatischen Ansatz zur Modellierung der A-priori-Verteilungen betroffener Typen von Entitäten und Relationen stellt daher der oben genannte Kompromiss dar, nämlich die Definition der Verteilungen auf Basis einer statistischen Analyse. Zu diesem Zweck kann für eine zu modellierende Qualität zunächst eine Stichprobe der relevanten Werte für den entsprechenden Typ von Entität ermittelt werden. Die Werte können dabei aus existierenden Wissensmodellen, Datenbanken oder anderen verfügbaren Quellen bezogen werden. Handelt es sich um eine perzeptive Qualität, lassen sich entsprechende Werte auch algorithmisch ermitteln, z. B. unter Verwendung von Methoden der Bildverarbeitung. In diesem Fall muss allerdings zunächst entsprechendes Bildmaterial für die zu modellierenden Objekte bezogen werden. Aus diesem Bildmaterial können ggf. Werte für unterschiedliche perzeptive Qualitäten ermittelt werden (z. B. Farbe und Form). Liegt eine Stichprobe mit entsprechenden Werten für eine Qualität vor, kann z. B. mittels einer Kerndichteschätzung eine Wahrscheinlichkeitsverteilung erzeugt werden. Die objektorientierte Umweltmodellierung geht grundsätzlich von unsicherheitsbehafteten Messungen aus. Dies trifft z. B. auch für algorithmisch ermittelte Stichprobenwerte zu. Die Messunsicherheit des Algorithmus kann daher in der Kerndichteschätzung zur Bestimmung der Bandbreite der eingesetzten Kerne verwendet werden. Als Typ von Kern bieten sich für die objektorientierte Umweltmodellierung Gaußkerne an. Die erzeugte Wahrscheinlichkeitsverteilung kann anschließend noch generalisiert werden, z. B. über Ansätze zur Komponentenreduktion für Gaußmischverteilungen, ähnlich zum in Abschnitt 8.4.3 beschriebenen Vorgehen beim Konzeptlernen.

4.6 Wissensmodell für die Haushaltsumgebung

Zur Demonstration der Einsetzbarkeit und des Nutzens von Metamodell und Kern-Ontologie wurde beispielhaft ein Hintergrundwissensmodell erstellt. Dieses Modell betrachtet eine menschliche Haushaltsumgebung als Domäne und verschiedene küchenbezogene Aufgaben als Anwendung. Das Modell ist als eine Ontologie in OWL 2 DL umgesetzt und erweitert die Kern-Ontologie der objektorientierten Umweltmodellierung. Nachfolgend wird das entworfene Modell sowie das Vorgehen zu dessen Entwicklung im Überblick beschrieben.

4.6.1 Modellentwurf

Einem strukturierten Vorgehen zum Ontologie-Entwurf folgend (vgl. Abschnitt 2.2.3), wurde zunächst in einer Analysephase der Einsatzzweck der Ontologie definiert und es wurden entsprechende Kompetenzfragen formuliert. Dabei wird ein schichtenweiser Aufbau der Ontologie umgesetzt. Anschließend an die Analyse fand die Kategorisierung und Konzeptualisierung der relevanten Begriffe statt sowie ihre Einordnung in eine Taxonomie. Zuletzt werden die festgelegten Konzepte formal definiert. Auf diese Entwurfsaspekte wird nachfolgend eingegangen, die Umsetzung des Hintergrundwissensmodells wird anschließend in Abschnitt 4.6.2 vorgestellt.

Einsatzzweck Der Anwendungszweck des Modells ist die Modellierung von Wissen über Anteile der Domäne des menschlichen Haushalts. Weiterhin dient das Modell allgemein zur Festlegung der Terminologie, in welcher Aussagen über die Domäne getroffen werden können. Als konkreter Anwendungsfall soll ein Serviceroboter als technisch kognitives System bei der Erfüllung von küchenbezogenen Aufgaben unterstützt werden.

Aufbau Um Wiederverwendbarkeit für die allgemeineren Anteile des modellierten Wissens zu ermöglichen, wurde das Modell aufgeteilt in eine übergeordnete Domänen-Ontologie, welche allgemeineres Wissen für die Haushaltsdomäne modelliert, und eine Anwendungs-Ontologie, in welcher aufgabenspezifischeres Wissen modelliert wird.

Kompetenzfragen Die Konzeption eines Wissensmodells beinhaltet die Identifizierung und Kategorisierung relevanter Begriffe für die Domäne und Anwendung. Diese Entwurfsaufgabe kann durch Kompetenzfragen unterstützt werden. Kompetenzfragen dienen dabei als Orientierung für die Auswahl und Modellierung der zu repräsentierenden Domänen-Entitäten und Beziehungen. Für das entwickelte Hintergrundwissensmodell ergeben sich folgende Kompetenzfragen:

- Welche Vorgänge sind relevant im menschlichen Alltag, speziell in Bezug auf küchenbezogene Aufgaben?
- Und je Vorgang im Detail:
 - Wer führt einen Vorgang aus: nur ein Mensch oder auch ein Serviceroboter? Und gibt es auch Geräte oder Gegenstände, die die Durchführung des Vorgangs durch eine entsprechende Funktion ermöglichen oder unterstützen?
 - Wer oder was ist das Objekt eines solchen Vorgangs? Beispielsweise verzehrt ein Mensch Lebensmittel, kocht ein Wasserkocher Wasser oder unterhält ein Radio einen Menschen.
- Welchem Zweck oder in welcher Rolle dient ein bestimmter Gegenstand im menschlichen Alltag, welche Funktion hat ein Gerät?
- Welche weiteren Eigenschaften in Bezug auf Küchen- oder Haushaltsaufgaben besitzt ein bestimmter Gegenstand? Darunter beispielhaft:
 - Wie permanent ist die Position eines Gegenstandes (z. B. innerhalb eines Zimmers)?
 - In welchen Gefäßen werden bestimmte Stoffe (im Sinne von Substanzen) aufbewahrt?
 - Aus welchen Stoffen wird ein Produkt hergestellt, und welche Inhaltsstoffe besitzt es?

- Muss ein Gegenstand gekühlt werden (z. B. Gegenstände, die als Lebensmittel dienen)?
- Welche Stoffe sind bei Zimmertemperatur fest, welche sind flüssig, welche sind allgemein pulvrig?

Weiterhin sollen neben den zuvor genannten semantischen Aspekten auch perzeptive Eigenschaften modelliert werden:

- Was sind die definierenden wahrnehmbaren (perzeptiven) Eigenschaften eines gegenständlichen Konzepts?
 - Diese Information wird zur Klassifikation von Repräsentanten im Weltmodell mittels probabilistischer Assoziation benötigt. Sie betrifft sowohl die Frage, welche Eigenschaften (d. h. Qualitäten in DOLCE) für die Klassifikation relevant sind, als auch deren konkrete Werte (in Form von DoB-Verteilungen) für das betrachtete Konzept.

Kategorisierung Allgemein wurden in Bezug auf die Haushaltsdomäne und speziell für küchenbezogene Aufgaben unter Beachtung obiger Kompetenzfragen relevante Begriffe identifiziert, analysiert und kategorisiert. Eine erste Unterscheidung fand anhand der in DOLCE definierten Kategorien statt. Als Perdurant¹ wird dabei Vorgängliches² mit untergeordneten Vorgängen und Zustandsaktivitäten unterschieden von Enduranten³, also physischen Objekten, wie Gegenständen oder Stoffmengen, und nichtphysischen Objekten wie Rollen. Für Vorgänge wurden im entwickelten Modell menschliche Handlungen (Zubereiten, Verzehren, Reinigen, Schneiden, Transportieren, etc.) sowie allgemeine Vorgänge (Eingefrieren, Auftauen etc.) als Kategorien identifiziert. Als Zustandsaktivitäten wurden menschliche Aktivitäten (Sitzen, Schlafen, Essen von Mahlzeiten, Wohnen etc.) sowie allgemeine Aktivitäten mit Zustandscharakter (Aufbewahren, Kühlen etc.) als Kategorien identifiziert.

¹ Zur Erinnerung: Entitäten, die in der Zeit existieren.

² Im Modell bezeichnet als „VorgänglicherPerdurant“ bzw. in DOLCE englisch „Stative“.

³ Zur Erinnerung: Entitäten, die zu jedem Zeitpunkt existieren.

Als physische Objekte werden im Modell unterschiedliche Gegenstände und Stoffe¹ modelliert. Stoffe werden in der Domänen-Ontologie anhand ihrer Erscheinungsform bei Zimmertemperatur unterschieden, z. B. als Flüssigkeiten und Pulver. Als Gegenstände werden gegenständliche Objekte der Haushaltsumgebung modelliert. Der OntoClean Methodik [Gua02] folgend wurden bei der Modellierung von Gegenstandskonzepten die essentiellen Eigenschaften eines Gegenstandes von den möglichen Rollen seiner alltäglichen Verwendung durch den Menschen unterschieden. Ein Apfel ist beispielsweise essentiell ein gegenständliches Objekt mit bestimmten Abmessungen und einer gewissen Masse, aber nicht jeder Apfel ist notwendigerweise Nahrung für ein Lebewesen. Daher wurden Rollen, in welchen Gegenstände für den Menschen im Haushalt dienen, als weitere Kategorie identifiziert. Rollen (wie Lebensmittel, Möbel etc.) sind dabei als eigene Konzepte modelliert unterhalb der nichtphysischen Objekte in DOLCE. Rollen und die Gegenstände, die diese in der Haushaltsdomäne erfüllen, sind im Modell über Beziehungen verbunden, welche die Bedeutung eines Gegenstands für den menschlichen Alltag zum Ausdruck bringen.

Taxonomie Wie zuvor erwähnt wurde die OntoClean Methodik [Gua02] als grundlegendes Vorgehen zur Strukturierung des Hintergrundwissensmodells ausgewählt und angewendet. Dieses Vorgehen definiert ein taxonomisches Grundgerüst², welches zunächst nur aus den rigiden Konzepten eines Modells besteht. Ein rigides Konzept beschreibt dabei nur Eigenschaften, die essentiell für alle Instanzen dieses Konzepts sind [Gua02]. Nachdem dieses Grundgerüst feststeht, werden die weiteren, nicht-rigiden Konzepte des Modells in das Grundgerüst geeignet eingehängt [Gua04]. Dabei gelten Anforderungen an die möglichen taxonomischen Spezialisierungsbeziehungen („is-a“-Beziehungen) zwischen Konzepten, welche Spezialisierungen zwischen bestimmten Arten von Konzepten verbieten [Gua02]. Die

¹ Genauer gesagt werden Stoffe in DOLCE nicht als Substanzen betrachtet, sondern als konkrete Mengen eines Stoffs. Eine Instanz des Konzeptes Wasser, modelliert als Stoff, beschreibt somit eine bestimmte Menge Wasser, wie einen Liter Wasser oder das Wasser in einem Gefäß.

² Im Original: „backbone taxonomy“

Konzepte eines Modells werden bei diesem Vorgehen zunächst durch Meta-Eigenschaften annotiert (wie ob ein Konzept rigide ist etc.). Durch dieses Vorgehen kann eine Vereinfachung der taxonomischen Beziehungen zwischen Konzepten erreicht werden. Teilweise lassen sich komplexe Polyhierarchien in klar strukturierte Taxonomien umwandeln, welche als Grundgerüst eine Baumstruktur aufweisen. Die nicht erlaubten Spezialisierungsbeziehungen zwischen Konzepten werden durch andersartige Beziehungen zwischen den Konzepten ersetzt.

Dieser Ansatz wurde auch für das Hintergrundwissensmodell umgesetzt. Er betrifft hauptsächlich die bereits erwähnte Auftrennung zwischen Gegenständen und ihren Rollen im menschlichen Alltag. Alle Rollen sind dabei als soziale, nichtphysische Objekte¹ in einer eigenen Teilhierarchie unterhalb des Konzepts „MenschlicheRolleFürPhysischesObjekt“ modelliert. Dabei werden z. B. Lebensmittel, Einrichtungsgegenstände, Kleidung, Werkzeuge und Geräte unterschieden. Gegenstände² sind in DOLCE als physische Objekte modelliert, neben handelnden Objekten³, welche im entwickelten Modell als Konzepte z. B. Lebewesen wie Menschen, Tiere und Pflanzen enthalten sowie Serviceroboter. Reduziert um ihre Rolle im menschlichen Alltag könnte der Großteil der gegenständlichen Objekte der Haushaltsdomäne im Prinzip direkt unterhalb des Konzepts Gegenstand modelliert werden. Im entwickelten Modell wird allerdings eine gewisse Strukturierung der relevanten Gegenstände genutzt. Dabei werden natürliche Erzeugnisse (z. B. ein Apfel) von Produkten (z. B. eine Tasse) unterschieden. Produkte werden der Übersichtlichkeit weiter in Kategorien unterteilt, die beschreiben, ob ein Produkt spezielle Eigenschaften besitzt (Elektrogerät, Gefäß etc.) oder für welche Anwendung es produziert wurde (Nahrungsprodukt, Reinigungsprodukt etc.). Die Eigenschaft, für eine bestimmte Anwendung produziert worden zu sein, wird für das Modell somit als rigide angenommen.

¹ Objekte, die in ihrer Bedeutung von einer sozialen Gemeinschaft abhängen, wie der menschlichen Gesellschaft eines bestimmten Kulturkreises.

² In DOLCE: „Non-agentive Physical Object“

³ In DOLCE: „Agentive Physical Object“

Definition Schließlich wurden für die identifizierten Begriffe Konzepte definiert und formal repräsentiert. Vorgänge haben dabei i. A. Subjekte, welche den Vorgang ausführen können (ein Mensch oder ein Serviceroboter, nur ein Mensch) sowie Objekte, welche vom Vorgang betroffen sind (ein Gegenstand, ein Mensch etc.). Bei Zustandsaktivitäten werden rein menschliche Aktivitäten von anderen Aktivitäten unterschieden. Erstere haben dabei nur Menschen als Subjekte und besitzen i. A. keine Objekte. Alle weiteren Zustandsaktivitäten besitzen Objekte. Subjekte und Objekte werden über die Beziehungen „hatSubjekt“ und „istVorgangsObjektVon“ modelliert.

Ebenfalls mittels Beziehungen wird spezifiziert, welche Gegenstände und Geräte zur Durchführung eines Vorgangs (z. B. Tafelbesteck beim Verzehren, eine Backform zum Backen) oder einer Zustandsaktivität (z. B. Stuhl zum Sitzen, Bett zum Schlafen) genutzt werden sowie welche Funktionen von Elektrogeräten (z. B. Gefrierschrank zum Einfrieren) etwas Vorgängliches ermöglichen. Zu diesem Zweck dienen die Beziehungen „ermöglichtVorgang“ für Vorgänge und „dientZum“ für Zustandsaktivitäten bzw. ihre inversen Beziehungen. Zusätzlich wird die Funktion von Elektrogeräten über die Beziehung „hatFunktion“ modelliert. Gegenstände und Geräte, die bei einem Vorgang unterstützen, werden über die Beziehung „ermöglichtUnterstützungBeiVorgang“ beschrieben. Dieses Vorgehen ermöglicht die Modellierung von Wissen über Vorgänge beispielsweise derart, dass ein Backofen die Funktion Backen besitzt und das Backen als einen Vorgang ermöglicht, welcher durch eine Backform unterstützt wird.

Gegenstände, welche in bestimmten Rollen dienen, werden über die Beziehung „dientInRolleAls“ bzw. deren Spezialisierung für Lebensmittel „dientInRolleAlsLebensmittel“ mit ihren Rollen verbunden. Rollen sind im Gegensatz von diesen Gegenständen abhängig. Weiterhin kann über Beziehungen zwischen physischen Enduranten (hauptsächlich Gegenständen und Stoffen) beschrieben werden,

- in welchen Gefäßen etwas aufbewahrt oder transportiert wird,
- welche Zutaten und Inhaltsstoffe ein Nahrungsprodukt besitzt sowie
- welche Produkte verderblich, zu kühlen oder tiefgekühlt sind.

4.6.2 Umsetzung

Nachfolgend wird die Umsetzung des entwickelten Hintergrundwissensmodells in der Repräsentationssprache OWL vorgestellt, aufgeteilt in die beiden Anteile Domänenmodell und Anwendungsmodell.

Domänenmodell

Für das Domänenmodell werden die modellierten Qualitäten, Arten von Vorgängen und Objekte der Domäne beschrieben.

Qualitäten Die Qualitäts-Taxonomie der Domänen-Ontologie ist ausschnittsweise in Abbildung 4.11 dargestellt. Die Abbildung zeigt die definierten physischen und temporalen Qualitäten des Modells, nichtphysische Qualitäten wurden auf der Ebene des Domänenmodells nicht definiert. Als physische Qualitäten werden auf der Ebene des Domänenmodells beispielhaft einige Qualitäten modelliert, die grundlegend relevant für die

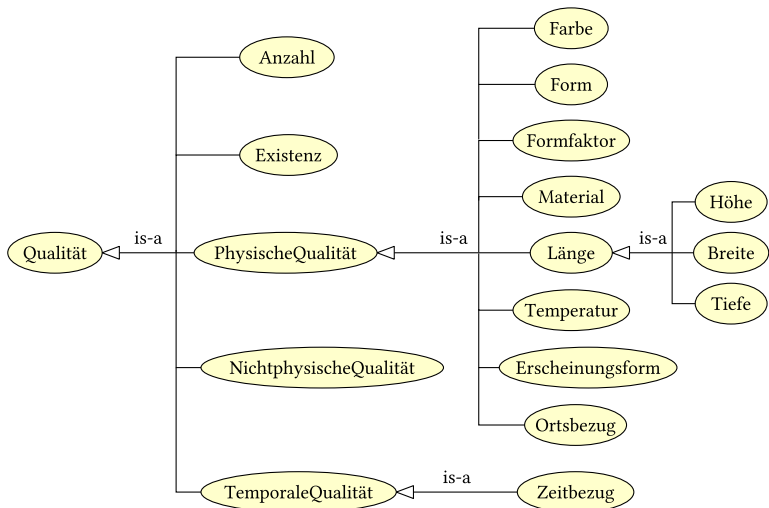


Abbildung 4.11: Modellierte Qualitäten der Domänen-Ontologie im Hintergrundwissensmodell für die menschliche häusliche Domäne.

Haushaltsdomäne sind. Dies betrifft Qualitäten, welche z. B. als perzeptive Qualitäten bei der Erkennung von Objekten dienen können, wie deren Abmessungen, Form, Farbe oder Material. Weiterhin wird die Temperatur und Erscheinungsform von Objekten modelliert. Die Erscheinungsform wird hier bereits auf ein nominales Skalenniveau festgelegt und als Enumeration mit einem entsprechenden Wertebereich (fest, flüssig, halbfest, pulverig, gasförmig etc.) definiert. Die Erscheinungsform dient im Domänenmodell dabei als eine semantische Qualität, mit welcher Vorwissen im Modell hinterlegt wird. Dies betrifft z. B. Aussagen in Bezug auf die Handhabung von Stoffen, wie dass Flüssigkeiten oder Pulver unter Zuhilfenahme von Gefäßen transportiert werden müssen.

Perduranten Als Perduranten werden im Domänenmodell nur vorgängliche Perduranten detaillierter modelliert, keine Ereignisse. Die Kategorie der vorgänglichen Perduranten beschreibt dabei Perduranten, welche z. B. allgemeine, unspezifische Vorgänge darstellen, wie Sitzen oder Gehen, wohingegen die Kategorie Ereignisse spezifische Vorgänge beschreibt, wie eine Fahrt von Ort A nach Ort B. Zur Modellierung von Vorwissen für die objektorientierte Umweltmodellierung sind daher die Kategorie der vorgänglichen Perduranten sowie ihre beiden untergeordneten Kategorien Vorgang und Zustandsaktivität relevant. Die auf der Ebene des Domänenmodells modellierten Vorgänge sind in Abbildung 4.12 dargestellt, die Zustandsaktivitäten in Abbildungen 4.13.

Dabei werden beispielhaft bestimmte menschliche Tätigkeiten und allgemeine Vorgänge modelliert, die in Beziehung zu relevanten Objekten der Haushaltsdomäne stehen und durch diese Objekte ermöglicht oder unterstützt werden. Somit soll Vorwissen über Objekte der Domäne und ihre Bedeutung im menschlichen Alltag repräsentiert werden. Die modellierten Konzepte für Vorgänge und Zustandsaktivitäten werden hierfür mittels der oben erwähnten Relationen („hatSubjekt“, „istVorgangsObjektVon“, „ermöglicht-Vorgang“, „istFunktionVon“ etc.) axiomatisiert und mit Objekten, bzw. allgemeinen Enduranten, in Beziehung gesetzt.

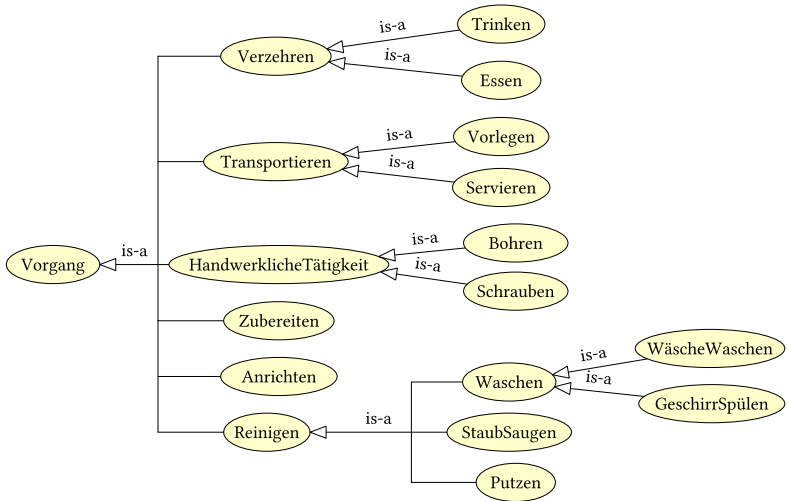


Abbildung 4.12: Modellierte Vorgänge auf Ebene des Domänenmodells für die menschliche häusliche Domäne.

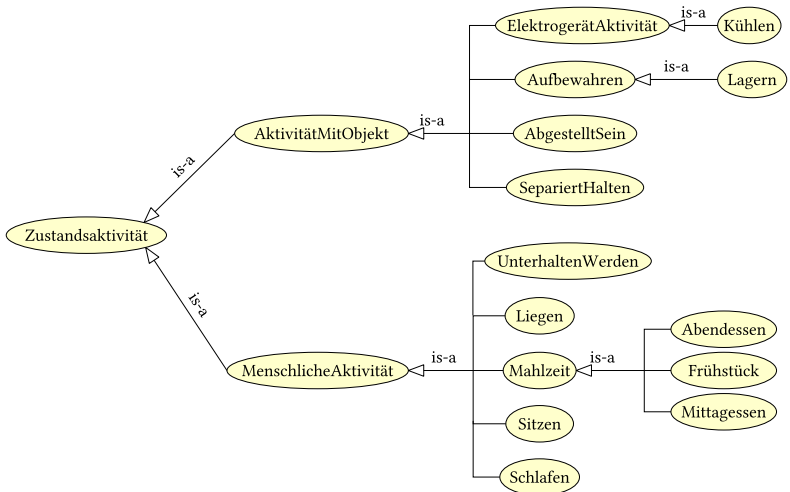


Abbildung 4.13: Modellierte Zustandsaktivitäten auf Ebene des Domänenmodells für die menschliche häusliche Domäne.

Enduranten und Rollen Die auf der Ebene des Domänenmodells definierten Enduranten sind in Abbildung 4.14 ausschnittsweise dargestellt, mit einem Fokus auf der Kategorie der von Menschen produzierten Gegenstände. Die entsprechenden Konzepte sind, neben ihren Relationen zu Vorgängen, auch über ihre Beziehungen zu den Rollen, in welchen sie in der Haushaltsdomäne dienen, axiomatisiert. Hierbei wird die Relation „dientZum“ verwendet. Die auf der Ebene des Domänenmodells definierten menschlichen Rollen, welche als Ziel dieser Relation dienen, sind in Abbildung 4.15 dargestellt.

Anwendungsmodell

Auf der Ebene des Anwendungsmodells wird die entwickelte Ontologie für die Haushaltsdomäne um zahlreiche weitere Konzepte für Gegenstände, Stoffe, Rollen, Vorgänge und Zustandsaktivitäten erweitert. Ziel ist auch hier, die Bedeutung von Gegenständen und Stoffen, welche für küchenbezogene Aufgaben relevant sind, über Beziehungen zu ihren Rollen und ermöglichten Vorgängen zu formalisieren. Insgesamt werden im entwickelten Hintergrundwissensmodell über alle Ebenen ungefähr 1000 verschiedene Klassen mit über 2500 logischen Axiomen modelliert (ohne reine Konzeptdefinitionen).

Anwendungsspezifische Rollen und Enduranten Zu diesem Zweck wurden ernährungsspezifische Rollen (Lebensmittel, feste Nahrung, Getränke, Genussmittel, Gewürz, Gericht etc.), küchenbezogene Rollen (Besteck mit Ess- und Servicebesteck, Reinigungsmittel etc.) sowie weitere allgemeine Rollen (z. B. Kleidung) in der Ontologie ergänzt. Erfüllt werden diese Rollen durch unterschiedliche Stoffe und Gegenstände. Als konkrete Stoffe wurden küchen- bzw. ernährungsrelevante Flüssigkeiten (Wasser, Milch etc.), Pulver (Mehl, Salz, Pfeffer etc.), halb feste Stoffe (Joghurt, Honig etc.) sowie Inhaltsstoffe (Koffein, Alkohol, Vitamin, Natrium etc.) modelliert. Als relevante Gegenstände wurden natürliche Erzeugnisse (Ei, verschiedene Obst- und Gemüsesorten etc.), gegenständliche Nahrungsprodukte (Brot, Brötchen, Wurst-, Fleisch- und Käsesorten, Säfte etc.), konkrete Geschirr-



Abbildung 4.14: Ausschnitt der modellierten Gegenstände in der Domänen-Ontologie für die menschliche häusliche Domäne.

und Besteckanteile (Teller, Tassen, Töpfe, Schalen, Gefäße, Gabeln, Messer etc.) sowie Elektrogeräte (Kühlschrank, Toaster, Herd, Mixer, Staubsauger) modelliert. Auch bautechnische Konstruktionen (Zimmer, Wand, Tür,

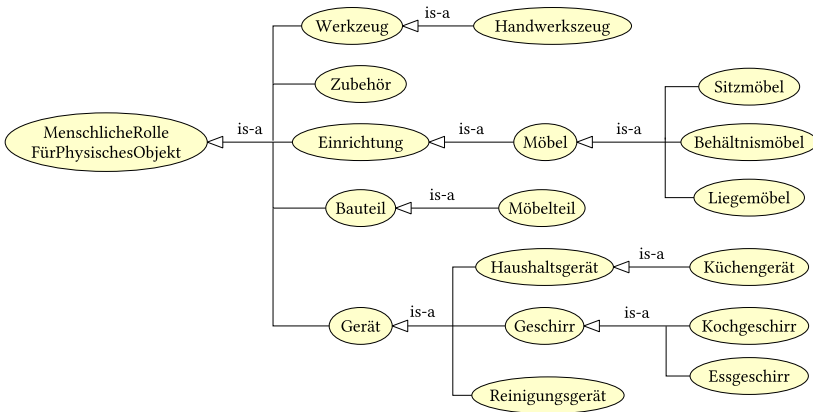


Abbildung 4.15: Ausschnitt der modellierten Rollen in der Domänen-Ontologie für die menschliche häusliche Domäne.

Fußboden etc.) wurden ergänzt. Für die semantische Beschreibung dieser Gegenstände und Stoffe wurden weitere küchenbezogene Relationen ergänzt („hatInhaltsstoff“, „hatZutat“, „wirdAufbewahrtIn“ etc.).

Zusätzliche Perduranten Ebenfalls wurden weitere Vorgänge für Küchenaufgaben definiert (Auftauen, Einfrieren, Aufspießen, Schöpfen, Backen, Braten) bzw. existierende Vorgänge spezialisiert (Schneiden von Brot, Schneiden von Obst, Aufbrühen von Kaffee, Aufbrühen von Tee etc.). Diese Spezialisierung erfolgte in Fällen, wo dies einer Präzisierung der Verwendung von Objekten im Küchenalltag diene („Brotmesser“ gegenüber „Käsemesser“). Ähnlich wurde für Zustandsaktivitäten verfahren (z. B. in Bezug auf das Aufbewahren unterschiedlicher Arten von Lebensmitteln).

Qualitäten Weiterhin wurden zusätzliche Qualitäten in das Anwendungsmodell aufgenommen. Mittels dieser Qualitäten kann beispielsweise der Nährwert oder die Schädlichkeit von Stoffen und Gegenständen beschrieben werden, wenn diese als Lebensmittel genutzt werden. Ebenso kann der Wassergehalt bzw. Alkoholgehalt repräsentiert werden. Diese Qualitäten dienen im Anwendungsfall des entwickelten Hintergrundwissensmodells als semantische Qualitäten, mit welchen Vorwissen im Modell repräsentiert

wird. Im Speziellen ermöglichen sie die Definition von Sammelkategorien, welche eine sprachliche Bedeutung im menschlichen Alltag haben, z. B. die Kategorie der alkoholischen Getränke oder die Unterscheidung von Nahrungsmitteln gegenüber Genussmitteln.

Als weitere Qualitäten werden die Ortsfestigkeit eines Gegenstandes sowie dessen üblicher Ort definiert. Die Ortsfestigkeit beschreibt dabei mittels eines nominalen Attributs, ob für einen Gegenstand angenommen werden kann, dass dieser über die Zeit am gleichen Ort verbleibt (Wert „ortsfest“), dies zumindest annähernd gilt („annähernd ortsfest“) oder nicht gilt („ortsvariabel“). Der übliche Ort beschreibt eine Ortsangabe für den Fall, dass man nach einem Gegenstand einer bestimmten Art sucht. Beide Qualitäten dienen im Anwendungsfall sowohl als semantische als auch als deduktive Eigenschaften: einerseits ermöglichen sie, klassenspezifisches Vorwissen ins Hintergrundwissensmodell einzubringen (ein Schrank ist ortsfest, ein Stuhl annähernd ortsfest, Kaffeetassen sind ortsvariabel), andererseits können, als eine Art des Konzeptlernens, entsprechende Informationen mit der Zeit als Erfahrungswissen aus der Historie des Weltmodells abgeleitet werden (z. B. der übliche Ort, an welchem eine Küchenrolle aufbewahrt wird).

Als perzeptive Qualitäten für die Anwendung dienen Spezialisierungen der im Domänenmodell definierten Qualitäten Farbe, Form, Formfaktor, Abmessungen und Material. Zur Beschreibung der Farbe von Objekten wird die Qualität Farbe des Domänenmodells in zwei zusätzliche Qualitäten, eine Primärfarbe und eine Sekundärfarbe, spezialisiert. Beide Farbqualitäten werden dabei symbolisch auf einem nominalen Skalenniveau beschrieben. Die Qualität Material wird ebenfalls in ein Primär- und Sekundärmaterial spezialisiert und symbolisch auf nominalem Skalenniveau beschrieben. Auch die Qualität Form wird auf nominalem Skalenniveau beschrieben. Zusätzlich werden weiterhin mehrere Formfaktoren definiert, welche jeweils bestimmte Aspekte der Objektform als stetige Merkmale intervallskaliert beschreiben. Die Abmessungen eines Objektes werden in Form eines quaderförmigen Hüllkörpers über die drei Qualitäten Tiefe, Breite und Höhe jeweils verhältnisskaliert beschrieben.

Probabilistische Modellierung Die schrittweise Erstellung eines Hintergrundwissensmodells der objektorientierten Umweltmodellierung ermöglicht es, zunächst ein relationales Modell der Domäne zu definieren und dieses anschließend um probabilistische Aspekte wie unsichere Attribute und Relationen zu erweitern. Für die Erstellung des Hintergrundwissensmodells für Haushaltsaufgaben wurde ebenfalls eine schrittweise Herangehensweise gewählt. Die vorausgehende Beschreibung des erstellten Domänen- und Anwendungsmodells betraf dabei den relationalen Anteil. Auf dieser Grundlage können nun probabilistische Attribute zu den definierten Konzepten hinzugefügt werden. Dabei wurden zunächst, wie im Abschnitt 4.5 beschrieben, nur Blattkonzepte der Generalisierungshierarchie betrachtet.

Die probabilistische Modellierung erfolgte dabei in Abhängigkeit der im relationalen Modell definierten Skalenniveaus und Wertebereiche je Qualität. Für nominale Qualitäten wie Farbe, Form und Material wurden z. B. entsprechende Attribute mit diskreten Wahrscheinlichkeitsverteilungen modelliert. Für kardinal skalierte Qualitäten wie die Abmessungen oder Formfaktoren wurden Attribute mit Normalverteilungen oder Gaußmischverteilungen definiert. Wie bereits erwähnt werden probabilistisch modellierte Attribute in der Kern-Ontologie in Form von semantischen Netzen dargestellt. Abbildung 4.16 illustriert beispielhaft die Anteile, die für eine probabilistische Modellierung eines Attributs festgelegt werden müssen. Dabei wird die Modellierung der kardinalen Qualität Breite für das Konzept Gabel mittels eines normalverteilten Attributs dargestellt.

Ein konkretes Attribut stellt sich dabei als das semantische Netz von Instanzen zu den entsprechenden Konzepten der Kern-Ontologie dar. Instanzen sind in der Abbildung als rote Rechtecke dargestellt, ihre Konzepte als gelbe Ellipsen und Datenwerte in grün. Die Verteilung der möglichen Breite-Werte einer Gabel wird dabei über eine Instanz der Qualität Breite („Breite-Gabel“) dargestellt, zu welcher das Konzept Gabel in einer Relation des Typs „besitzt-Qualität“ steht. Die Breite-Instanz selbst steht in Relation „hatAttribut“ zur Instanz „Att(ribut)-Breite-Gabel“ eines verhältnisskalierten Attributs. Diese

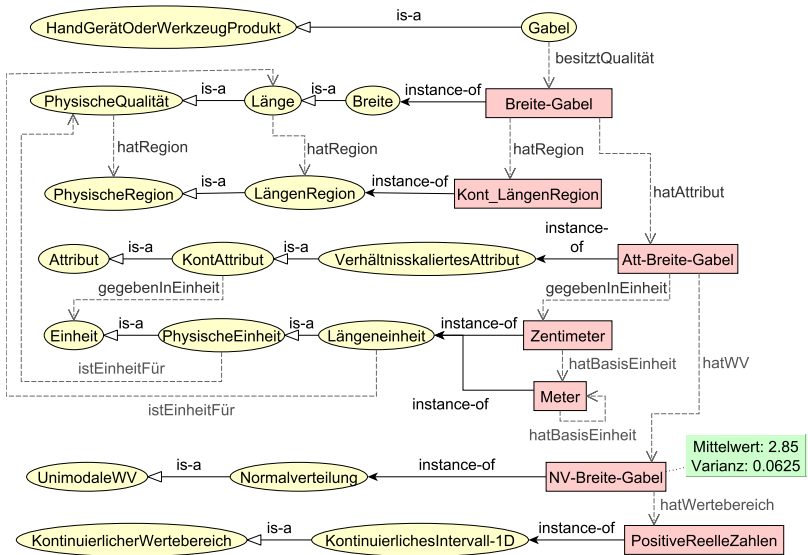


Abbildung 4.16: Probabilistische Modellierung der kardinalen Qualität Breite für das Konzept Gabel mittels eines normalverteilten Attributs im Anwendungsmodell für die menschliche häusliche Domäne. Die konkrete Breite einer Gabel wird in Form eines semantischen Netzes für die Instanz „Breite-Gabel“ der Qualität Breite repräsentiert. Dabei werden weitere Instanzen für Attribute, Wertebereiche, Maßeinheiten etc. zur Beschreibung der konkreten Qualität referenziert. Instanzen sind in der Abbildung als rote Rechtecke dargestellt, ihre Konzepte als gelbe Ellipsen und Datenwerte in grün.

Attribut-Instanz besitzt weitere Relationen zu einer Einheiten-Instanz („Zentimeter“) sowie zur Instanz „NV-Breite-Gabel“, welche die gewünschte Normalverteilung mit entsprechenden Datenwerten darstellt.

Derartige semantische Netze zur Darstellung von probabilistischen Attributen können automatisch erstellt und dem Wissensmodell hinzugefügt werden, wenn eine mathematische Beschreibung der Wahrscheinlichkeitsverteilung vorliegt (in zur Kern-Ontologie kompatibler Form) sowie die referenzierte Qualität und die entsprechende Domäne-Entitäten gegeben sind (vgl. Abschnitt 4.4.3 zur interoperablen Bereitstellung von Beobachtungen). Ebenfalls kann die Wahrscheinlichkeitsverteilung eines probabilistischen Attributs aus dem Wissensmodell automatisiert in eine mathematische

Form überführt werden, welche dann z. B. von anderen Komponenten des kognitiven Systems sowie im Umweltmodell selbst weiterverwendet werden kann (z. B. zur quantitativen Modellbewertung).

Wie in Abschnitt 4.5.2 beschrieben, muss eine probabilistische Modellierung in einem Hintergrundwissensmodell der objektorientierten Umweltmodellierung zwingend zunächst nur für diejenigen Konzepte erfolgen, welche durch Repräsentanten im Weltmodell instanziiert werden könnten. Dies betrifft i. A. die Blattkonzepte der Taxonomie. Zur Modellierung von probabilistischen Attributen für relevante Konzepte wurde der ebenfalls in Abschnitt 4.5.2 vorgeschlagene Ansatz einer stichprobenbasierten Modellierung genutzt. Für Details zu dieser probabilistischen Modellierung für die oben genannten perzeptiven Qualitäten im Anwendungsfall der Haushaltsumgebung mit Küchenaufgaben sei auf Abschnitt 8.5.1 verwiesen. Dort wird die probabilistische Modellierung ausgewählter gegenständlicher Objekte als Konzepte im Rahmen des Demonstration-Szenarios der quantitativen Modellbewertung beschrieben.

Dieses Vorgehen lässt sich auch auf semantische Attribute übertragen, für die eine ausreichende Menge an Beispielwerten ermittelt werden kann. Dies betrifft z. B. numerisch repräsentierte Qualitäten wie den Nährwert oder den Alkoholgehalt von Lebensmitteln. Ebenso lässt sich das Vorgehen auf Qualitäten übertragen, für welche grundsätzliches unsicheres Vorwissen repräsentiert werden soll. Dies betrifft z. B. die üblichen Orte für Gegenstände als solche Positionen, die entweder an sich nicht mit hoher Präzision angegeben werden können (Varianz) oder, bzw. zusätzlich, sich über die Zeit durch Alternativen auszeichnen (Multimodalität). Hier können z. B. Gaußmischverteilungen zur Repräsentation derartigen Vorwissens genutzt werden. Analog können Wahrscheinlichkeitsverteilungen für im Anwendungsfall deduktiv verwendete Attribute aus über die Zeit gesammelten Informationen als Erfahrungswerte abgeleitet werden.

4.7 Zusammenfassung

In diesem Kapitel wurde das für diese Arbeit entworfene Vorgehen zur Erstellung von Hintergrundwissensmodellen für die objektorientierte Umweltmodellierung vorgestellt und demonstriert. Dazu wurden zunächst die Anforderungen der objektorientierten Umweltmodellierung an ihre Hintergrundwissensmodelle erfasst, analysiert und dem Stand der Technik gegenübergestellt. Für die spezifischen Anforderungen der objektorientierten Umweltmodellierung, wie einer probabilistischen Repräsentation von Attributen auf unterschiedlichen Skalenniveaus, wurde ein eigenes Metamodell definiert und in OWL 2 DL umgesetzt. Zur Strukturierung der Inhalte eines Hintergrundwissensmodells wurde weiterhin mit DOLCE eine Top-Level Ontologie mit der Umsetzung des Metamodells integriert. Das integrierte Modell stellt dabei eine Kern-Ontologie für die objektorientierte Umweltmodellierung dar. Diese Kern-Ontologie dient im Weiteren auch als Voraussetzung für eine adaptive Umweltmodellierung, da sie den Hypothesenraum für neu zu lernende Konzepte definiert. Aufbauend auf dieser Kern-Ontologie wurde ein schrittweises Vorgehen zur Erstellung von Domänenmodellen für die objektorientierte Umweltmodellierung vorgeschlagen, schrittweise sowohl in Bezug auf die Spezialisierungsebene von Modellen als auch bzgl. der Nutzung von relationalen Modellen als Grundlage für die probabilistische Modellierung. Die Anwendbarkeit der Kern-Ontologie und des Vorgehens zur Modellerstellung wurden schließlich mit einem Hintergrundwissensmodell als Anwendungsbeispiel im Bereich der Servicerobotik für Haushaltsaufgaben demonstriert.

5 Probabilistische Informationsverwaltung in der Umweltmodellierung

In diesem Kapitel soll die probabilistische Informationsverwaltung und -verarbeitung der objektorientierten Umweltmodellierung dargelegt werden. Viele der dargestellten Aspekte betreffen dabei Anteile, welche in Vorarbeiten [Ghe08, Bel09, Ghe10b, Ghe10a, Hei10, Bau10] sowie anderen Arbeiten wie [Bel17] vorgeschlagen oder im Detail betrachtet werden. In dieser Arbeit und in diesem Kapitel werden nun spezifische Ziele diesbezüglich verfolgt. Ein Ziel ist es dabei, das Thema der Informationsverwaltung möglichst ganzheitlich zu betrachten und seine verschiedenen Aspekte integriert darzustellen. Dies soll unter Bezug und expliziter Verwendung des vorgeschlagenen Metamodells für das Hintergrundwissen und seiner definierten Konzepte erfolgen. Weiterhin sollen auch Stellen innerhalb der Informationsverwaltung identifiziert werden, welche als Ansatzpunkte für eine adaptive Umweltmodellierung und speziell das Lernen aus erworbenen Umgebungsinformationen relevant sind. Für die probabilistische Informationsverarbeitung, einem Teil der Informationsverwaltung im objektorientierten Umweltmodell, ist es weiterhin das Ziel, diese als einen ganzheitlichen Ablauf und in einer durchgängigen formalen Repräsentation darzustellen. In dieser integrativen Darstellungen werden an passenden Stellen zugleich eigene Ergänzungen durch konkrete Beispiele, Detaillierungen und, falls notwendig, eigene Anpassungen oder Erweiterungen eingeführt. Ersteres betrifft beispielsweise die Unterscheidung und unterschiedliche Handhabung der verschiedenen Arten von Attributen, welche im Metamodell des Hintergrundwissens in dieser Arbeit eingeführt wurden.

Dieses Kapitel ist wie folgt strukturiert. In Abschnitt 5.1 werden die Grundlagen der probabilistischen Informationsverarbeitung im objektorientierten Umweltmodell beschrieben. Beiträge dieser Arbeit beinhalten hier Detailierungen, die Verbindung zum Metamodell, konkrete Beispiele und eine durchgängige Notation. Abschnitt 5.2 geht spezifisch auf die Datenassoziation ein, die einen wichtigen Teil der Informationsverarbeitung darstellt. Eigene Beiträge bestehen hier aus einer Erweiterung und Anpassung des Vorgehens zur Datenassoziation. Anschließend wird in Abschnitt 5.3 die allgemeine Informationsverwaltung im Umweltmodell beschrieben, welche Repräsentanten und Relationen betrifft. Die Beiträge dieser Arbeit beinhalten hier ein alternatives Vorgehen zur Erzeugung neuer Repräsentanten, abgestimmt auf die angepasste Datenassoziation, sowie eine Konzeption für die Verwaltung von Relationen. Abschnitt 5.4 behandelt schließlich das Thema, wie erworbene Umgebungsinformationen längerfristig gespeichert und aus ihnen Erfahrungswerte gelernt werden können. Die Beiträge dieser Arbeit bestehen dabei in einer strukturierten Diskussion dieses Themas.

5.1 Probabilistische Informationsverarbeitung

Im objektorientierten Umweltmodell findet eine probabilistische Verarbeitung der erfassten Umweltinformationen statt. Basis dieser Informationsverarbeitung ist die probabilistische Informationsrepräsentation. Die probabilistische Informationsverarbeitung umfasst im objektorientierten Umweltmodell alle Operationen, die der Weiterverarbeitung der über die betrachtete Umgebung erworbenen Informationen dienen und die nach probabilistischen Prinzipien erfolgen. Die Informationsverarbeitung erfolgt unter Verwendung eines Zustandsraummodells für dynamische Anteile sowie unter Verwendung von DoB-Verteilungen zur Modellierung von Vorwissen. Im Weltmodell wird mittels der enthaltenen Repräsentanten und deren Beziehungen der aktuelle Zustand der beobachteten Umgebung eines kognitiven Systems repräsentiert. Das objektorientierte Umweltmodell arbeitet als ein

zeitdiskretes System, welches in jedem Zeitschritt ein Verarbeitungsschema durchläuft. Die wichtigsten Schritte dieses Verarbeitungsschemas werden nachfolgend im Überblick dargelegt. Anschließend wird die formale mathematische Repräsentation der probabilistischen Informationen für dieses Kapitel definiert und mittels dieser Repräsentation zwei der wichtigsten Verarbeitungsschritte detaillierter dargestellt.

5.1.1 Grundlegendes Verarbeitungsschema

Im Weltmodell werden eingehende Informationen zeitdiskret verarbeitet. Trifft in einem Zeitschritt t_k eine neue Beobachtung zu einer Domänen-Entität ein, so erfolgen verschiedene Verarbeitungsschritte. Diese Verarbeitungsschritte betreffen

- die zeitliche Fortschreibung existierender Informationen,
- die Zuordnung einer Beobachtung zu existierenden Informationen
- und die entsprechende Aktualisierung dieser Informationen.

Zunächst erfolgt eine zeitliche Fortschreibung (Prädiktion) des bisherigen Zustands des Weltmodells auf den aktuellen Zeitpunkt. Dies betrifft zunächst einmal alle im Weltmodell enthaltenen Repräsentanten. Dann wird versucht, die neue Beobachtung einem der Repräsentanten zuzuordnen (sog. Datenassoziation). Aufgrund dieser Zuordnung erfolgt dann eine Aktualisierung des Zustands im Weltmodell, bei welcher die Informationen der neuen Beobachtung mit den bisherigen Informationen im Weltmodell fusioniert werden oder ein neuer Repräsentant erzeugt wird. Im Anschluss an diese in jedem Zeitschritt durchgeführten Verarbeitungsschritte können weitere Schritte erfolgen. Diese weiteren Schritte betreffen

- die Aktualisierung der Typzuordnung für Repräsentanten,
- die Aktualisierung von Relationen zwischen Repräsentanten,
- die Prüfung, ob Repräsentanten zu löschen oder archivieren sind und
- allgemeine Qualitätsprüfungen.

Durch die in dieser Arbeit entwickelte adaptive Umweltmodellierung kommen noch weitere Schritte hinzu, welche die Bewertung der Modellqualität in Bezug auf die zu einem Zeitschritt im Weltmodell enthaltenen Repräsentanten sowie etwaige Modellanpassungen betreffen.

Die zuletzt genannten weiteren Schritte stellen im grundlegenden Verarbeitungsschema optionale Schritte dar, in dem Sinne, dass sie nicht in jedem Zeitschritt notwendigerweise ausgeführt werden müssen. Sie können alternativ regelmäßig, aber mit verringerter Frequenz ausgeführt werden. Auch eine ereignisgetriebene Ausführung kann sinnvoll sein, wobei z. B. eine externe Informationsabfrage als ein solches Ereignis dienen kann. Wann und mit welcher Häufigkeit diese weiteren Verarbeitungsschritte ausgeführt werden, ist dabei abhängig vom Anwendungsfall und dessen Anforderungen z. B. an eine Echtzeitfähigkeit des Umweltmodells. Dies stellt immer auch eine Abwägung gegenüber der Aktualität der repräsentierten Informationen dar. In Abschnitt 5.3.5 wird das genannte Verarbeitungsschema weiter detailliert, vor allem bzgl. der Verwaltung von Repräsentanten und Relationen.

Die Basiseinheiten der Informationsverarbeitung im Großteil der Verarbeitungsschritte stellen Attribute dar. Die für die objektorientierte Umweltmodellierung definierten Attribute können sich in verschiedenen, für eine Verarbeitung relevanten Aspekten unterscheiden, z. B. in ihrem Skalenniveau oder ihrem Szenarmodus¹. Auf diese Unterschiede wird nachfolgend an denjenigen Stellen, wo eine Unterscheidung notwendig ist, hingewiesen. Dabei werden auch entsprechend unterschiedliche Vorgehen genannt. Darüber hinaus wird die Behandlung von Attributen, soweit wie möglich, einheitlich dargestellt.

¹ Nach dem Metamodell der objektorientierten Umweltmodellierung (vgl. 4.3) besitzen nicht Attribute, sondern die von ihnen referenzierten Qualitäten ein Skalenniveau und einen Szenarmodus. Da jedes Attribut aber genau eine Qualität referenziert, wird hier verkürzend auch vom Skalenniveau bzw. Szenarmodus eines Attributs gesprochen.

5.1.2 Formale Informationsrepräsentation

An dieser Stelle sollen nochmals die grundlegenden Begriffe der objektorientierten Umweltmodellierung genannt und in Relation gesetzt werden sowie die in dieser Arbeit verwendete formale Repräsentation dieser Begriffe und Konzepte vorgestellt werden. Im Gegensatz zur formalen Darstellung von Vorwissen in der Wissensmodellierung steht in diesem Kapitel die mathematische Repräsentation der entsprechenden Verarbeitungsschritte im Vordergrund. Diese setzt naturgemäß ebenfalls auf etablierten Prinzipien und Modellelementen der objektorientierten Umweltmodellierung auf, z. B. auf Repräsentanten und deren Attributen.

Notation Dabei werden folgende Notationskonventionen genutzt:

- Zufallsvariablen werden fett dargestellt: \mathbf{x} ,
- Vektoren werden unterstrichen: \underline{x} ,
- Mengen werden in kalligraphischen Großbuchstaben dargestellt: \mathcal{R} ,
- Matrizen werden fett und in Großbuchstaben dargestellt: \mathbf{H} ,
- Dichtefunktionen von Zufallsvariablen werden mit Bezug zur Zufallsvariable als $p_{\mathbf{x}}(x)$ oder kurz als $p(x)$ dargestellt,
- bedingte Dichten werden (kurz) als $p(y|x)$ dargestellt,
- Realisierungen von Zufallsvariablen werden als \hat{y} dargestellt,
- Ereignisse werden mit Großbuchstaben beschrieben, z. B. als E , das Mengenkomplement eines Ereignisses wird als \bar{E} dargestellt.

Überblick

Die grundlegenden Begriffe der objektorientierten Umweltmodellierung und deren formale Darstellung mittels mathematischer Variablen wird in Tabelle 5.1 zusammengefasst. In der Weltmodell-Komponente des objektorientierten Umweltmodells werden beobachtete Domänen-Entitäten über Repräsentanten dargestellt. Ein Repräsentant wird formal als Symbol r dargestellt. Jeder Repräsentant wird über seine Attribute beschrieben. Ein Attribut a eines Repräsentanten r wird formal als a^r dargestellt. In der

Hintergrundwissens-Komponente des objektorientierten Umweltmodells werden Konzepte definiert, welche Typen von Domänen-Entitäten repräsentieren. Ein Konzept wird formal mit dem Symbol c dargestellt. In der probabilistischen Darstellung werden Attribute als Zufallsvariablen \mathbf{a} aufgefasst mit ihren entsprechenden DoB-Verteilungen, dargestellt als Dichtefunktionen $p(a)$. Auch Repräsentanten \mathbf{r} und Konzepte \mathbf{c} können als Zufallsvariablen aufgefasst werden mit entsprechenden Dichtefunktionen wie z.B. $p(r)$ für einen Repräsentanten.

Tabelle 5.1: Grundlegende Begriffe der Umweltmodellierung und ihre formale Darstellung.

Begriff	Symbole	Dichte
Repräsentant	r	$p_r(r), p(r)$
Konzept	c	$p_c(c), p(c)$
Attribut	a, a^r	$p_a(a), p(a^r)$
Existenz-Attribut	e^r, E^r	$p(e^r), p(E^r)$
Typ-Attribut	c^r	$p(c r)$
Assoziationsvariable	d_k, D_k	$p(d_k), p(D_k^r)$

Szenarmodus von Attributen Im Metamodell des Hintergrundwissens werden unterschiedliche Szenar Modi für Attribute unterschieden. Für perzeptive Attribute, deren Werte aufgrund von Sensorbeobachtungen bestimmt werden, gilt das oben genannte schritthaltende Verarbeitungsschema. Deduktive Attribute werden aus den Werten anderer Attribute bestimmt, nicht direkt aufgrund von Sensorbeobachtungen. Dies bedeutet, dass ihre Werte frühestens in den weiteren Schritten des Verarbeitungsschemas bestimmt werden. Genau genommen muss hier nach der Art und Weise unterschieden werden, wie ein deduktives Attribut bestimmt wird. Wird ein deduktives Attribut z.B. aus den aktuellen Werten perzeptiver Attribute bzw. dem aktuellen Zustand abgeleitet, so kann eine schritthaltende Aktualisierung sinnvoll sein. Wird es dagegen aus einer Historie von Werten abgeleitet, so kann eine regelmäßige Aktualisierung mit geringerer Frequenz bzw. eine Aktualisierung bei Bedarf sinnvoll sein. Semantische Attribute stellen Vorwissen dar und werden aus dem einem Repräsentanten

zugeordneten Konzept abgeleitet. Hier erfolgt i. A. eine Aktualisierung nur dann, wenn sich das zugeordnete Konzept ändert.

Spezielle Attribute Jeder Repräsentant besitzt zwei Attribute, die eine spezielle Semantik innehaben und daher auch eine spezielle Behandlung erfordern [Ghe10a]. Dies ist einerseits das Attribut, dass die Existenzwahrscheinlichkeit eines Repräsentanten darstellt, und andererseits das Typ-Attribut, welches die Zuordnung des Repräsentanten zu seinem Konzept im Hintergrundwissen im Sinne einer Klassifikation darstellt. Ein Existenz-Attribut wird dabei über eine binäre Zufallsvariable $e^r \in \{0,1\}$ repräsentiert, welche die Wahrscheinlichkeit beschreibt, dass der Repräsentant r aktuell zu einer realen Entität in der relevanten Umwelt korrespondiert. Diese Wahrscheinlichkeit wird nachfolgend als Existenzwahrscheinlichkeit bezeichnet. Ein Typ-Attribut c^r beschreibt dagegen den Typ von Entität, welche ein Repräsentant darstellt. Der Wertebereich eines Typ-Attributs ist somit die Menge der im Hintergrundwissen modellierten Konzepte (bzw. eine Teilmenge davon). Typ-Attribute speichern das Ergebnis der Repräsentant-zu-Konzept Zuordnung $p(c|r)$, einer Art von probabilistischer Klassifikation, und sind die Basis für eine sog. wissensbasierte Vervollständigung von Repräsentanten, also dem Ableiten der Werte für semantische Attribute. Zur sprachlichen Unterscheidung der allgemeinen Attribute eines Repräsentanten von seinem Existenz- und Typ-Attribut werden die allgemeinen Attribute in Vorarbeiten als deskriptive Attribute bezeichnet [Ghe10a]. Diese Bezeichnung wird nachfolgend so übernommen. Neben Repräsentanten besitzen auch probabilistische Relationen ein Existenz-Attribut. Ihre Typisierung erfolgt jedoch deterministisch.

Probabilistische Repräsentation von Repräsentanten

In formaler Notation [Ghe10a] kann ein Repräsentant r mittels seiner n Attribute $a^{r,i}$ durch die gemeinsame Wahrscheinlichkeitsverteilung

$$p(r) := p(c^r, a^{r,1}, a^{r,2}, \dots, a^{r,n}, e^r) \quad (5.1)$$

beschrieben werden. Deskriptive Attribute und das Typ-Attribut sind nur unter der Bedingung von Interesse, dass eine zum Repräsentanten korrespondierende Realwelt-Entität als existent angenommen wird, d. h. die Existenzvariable e^r den Wert 1 annimmt. Mit der Abkürzung $E^r := (e^r = 1)$ ergibt sich¹

$$p(r) = p(c^r, a^{r,1}, a^{r,2}, \dots, a^{r,n} | E^r) \cdot p(E^r) . \quad (5.2)$$

Unter Ausnutzung der Annahme der (bedingten) stochastischen Unabhängigkeit der deskriptiven Attribute lässt sich die Verteilung eines Repräsentanten weiter faktorisieren. Mit $\underline{a}^r := [a^{r,1}, a^{r,2}, \dots, a^{r,n}]^T$ ergibt sich

$$p(r) = p(c^r | \underline{a}^r, E^r) \cdot \left(\prod_{i=1}^n p(a^{r,i} | E^r) \right) \cdot p(E^r) . \quad (5.3)$$

Die Werte bzw. Wahrscheinlichkeitsverteilungen der Attribute von Repräsentanten ergeben sich aus den Informationen, welche mittels Sensorbeobachtungen der relevanten Umwelt an das objektorientierte Umweltmodell bereitgestellt werden. Eine im Zeitschritt t_k gemachte Beobachtung

$$\underline{\hat{y}}_k = [\hat{y}_k^1, \hat{y}_k^2, \dots, \hat{y}_k^s]^T \quad (5.4)$$

besteht dabei aus s einzelnen Messungen \hat{y}_k^j der durch die gegebenen Sensoren beobachtbaren Qualitäten einer Entität. Die Wahrscheinlichkeitsverteilung $p(r_k)$ eines Repräsentanten r im Zeitschritt t_k hängt dabei von allen bis zu diesem Zeitpunkt gemachten Beobachtungen, zusammengefasst im Vektor $\underline{\hat{y}}_{1:k}$, ab. Somit ergibt sich unter Angabe dieser Bedingungen für die

¹ Hier wird explizit $p(c^r, a^{r,1}, a^{r,2}, \dots, a^{r,n} | e^r = 0) = 0$ angenommen.

² Zufallsvektor mit diskreten und stetigen Zufallsvariablen

Wahrscheinlichkeitsverteilung eines Repräsentanten die Darstellung

$$p(r_k | \underline{y}_{1:k}) = p(c_k^r | \underline{a}_k^r, E_k^r, \underline{y}_{1:k}) \cdot \left(\prod_{i=1}^n p(a_k^i | E_k^r, \underline{y}_{1:k}) \right) \cdot p(E_k^r | \underline{y}_{1:k}) \quad (5.5)$$

Hier und im Folgenden wird bei der Notation der deskriptiven Attribute $\mathbf{a}^{r,i}$ der Übersichtlichkeit halber auf den Bezug zum Repräsentanten r verzichtet, solange dieser aus dem Kontext hervorgeht.

5.1.3 Informationsalterung

Die beobachtete Umgebung eines kognitiven Systems ist zeitlichen Veränderungen ausgesetzt [Ghe10a, Hei10]. Dies kann sich z. B. im Auftauchen oder Verschwinden von Domänen-Entitäten in der beobachteten Umgebung äußern, oder darin, dass sich die Eigenschaften von Domänen-Entitäten mit der Zeit ändern, z. B. ihre Position. Somit verlieren einmal erworbene und im Umweltmodell repräsentierte Informationen mit der Zeit einen Teil ihrer Gültigkeit. Diesem Fakt wird durch eine zeitliche Fortschreibung der im Weltmodell repräsentierten Informationen Rechnung getragen. Diese Fortschreibung wird in der objektorientierten Umweltmodellierung als Informationsalterung bezeichnet und betrifft die Existenz von Repräsentanten sowie ihre deskriptiven Attribute.

Fortschreibung der Existenzwahrscheinlichkeit

In jedem Zeitschritt reduziert sich nach diesem Prinzip die Existenzwahrscheinlichkeit eines Repräsentanten. Wird dieser Repräsentant im selben Zeitschritt erneut beobachtet, so erhöht sich seine Existenzwahrscheinlichkeit wieder, wie in Abschnitt 5.2 beschrieben. Zur Berechnung des Abklingens der Existenzwahrscheinlichkeit $p(E^r)$ für den Zeitschritt t_k (notiert als E_k^r) auf Basis der Existenzwahrscheinlichkeit $p(E_{k-1}^r)$ des vorhergehenden

Zeitschritts t_{k-1} werden die Übergangswahrscheinlichkeiten¹ [Ghe10a]

$$p(E_k^r | E_{k-1}^r) = \beta_c , \quad (5.6)$$

$$p(E_k^r | \bar{E}_{k-1}^r) = 0 , \quad (5.7)$$

genutzt, wobei β_c eine klassenspezifische Abklingkonstante mit $0 < \beta_c \leq 1$ beschreibt. Damit ergibt sich für die zeitliche Fortschreibung der Existenzwahrscheinlichkeit insgesamt die Formel

$$p(E_k^r | \underline{\hat{y}}_{1:k-1}) = \beta_c \cdot p(E_{k-1}^r | \underline{\hat{y}}_{1:k-1}) , \quad (5.8)$$

wobei $\underline{\hat{y}}_{1:k-1}$ hier alle bis zum Zeitpunkt t_{k-1} gemachten Beobachtungen beschreibt². Dieses Modell beschreibt dabei eine exponentielle Abnahme der Existenzwahrscheinlichkeit um den Faktor β_c , welcher vom Typ der Entität abhängt, d. h. vom dem Repräsentanten zugeordneten Konzept $c = c^r$. Dieser Alterungsfaktor kann zusammengesetzt sein [Bel09, Hei10], z. B. als

$$\beta_c = \beta_0 + \bar{\beta}_c + \bar{\beta}_s , \quad (5.9)$$

so dass sich der resultierende Alterungsfaktor β_c für Instanzen eines Konzepts c ergibt aus einem Basisfaktor β_0 , dem klassenspezifischen Alterungsfaktor $\bar{\beta}_c$ sowie einem weiteren Korrekturfaktor $\bar{\beta}_s$, mit welchem dem aktuellen Situationskontext Rechnung getragen werden kann.

Weiterhin sei angemerkt, dass durch die Verwendung eines klassenspezifischen Alterungsfaktors $\bar{\beta}_c$ eine Abhängigkeit zwischen der Typzuordnung $p(c|r)$ eines Repräsentanten und der Fortschreibung seines Existenzattributs entsteht. Dies kann dabei bewirken, dass sich unter einer geänderten Typzuordnung (z. B. aufgrund einer Aktualisierung) auch das Alterungsverhalten eines Repräsentanten ändert.

¹ Analog zu E^r werden hier die Abkürzungen $E_k^r := (e_k^r = 1)$ und $\bar{E}_k^r := (e_k^r = 0)$ verwendet.

² Die Wahrscheinlichkeit $p(\bar{E}_k^r | \underline{\hat{y}}_{1:k-1})$ ergibt sich dabei als $1 - p(E_k^r | \underline{\hat{y}}_{1:k-1})$.

Prädiktion von deskriptiven Attributen

Auch für die weiteren im Weltmodell gespeicherten deskriptiven Attribute wird in Vorarbeiten eine Alterung vorgeschlagen [Ghe08]. Konkret wird dazu der Prädiktionsschritt eines Bayes'schen Schätzers genutzt [Ghe10a, Bau10]. Zur Berechnung der auf den Zeitschritt t_k prädizierten Verteilung des Attributs \mathbf{a}^i eines Repräsentanten wird hier die Chapman-Kolmogorov Gleichung

$$p(\underline{a}_k^i | E_k^r, \underline{\hat{y}}_{1:k-1}) = \int p(\underline{a}_k^i | \underline{a}_{k-1}^i, E_k^r) \cdot p(\underline{a}_{k-1}^i | E_k^r, \underline{\hat{y}}_{1:k-1}) d\underline{a}_{k-1}^i \quad (5.10)$$

gelöst. Als Modell für die Transitionswahrscheinlichkeit $p(\underline{a}_k^i | \underline{a}_{k-1}^i, E_k^r)$ eines Attributs kann z. B. die Identitätsfunktion mit additivem Gauß'schen Rauschen angenommen werden, welches dann zu einer zeitlichen Erhöhung der Unsicherheit der Attributverteilung führt. Die Prädiktion des Attributvektors $\underline{\mathbf{a}}_k^r$ eines Repräsentanten \mathbf{r} lässt sich unter Ausnutzung der bedingten stochastischen Unabhängigkeit der einzelnen Attribute und nach (5.3) formal beschreiben als das Produkt

$$p(\underline{\mathbf{a}}_k^r | E_k^r, \underline{\hat{y}}_{1:k-1}) = \prod_i p(\underline{a}_k^i | E_k^r, \underline{\hat{y}}_{1:k-1}) . \quad (5.11)$$

Die konkrete Berechnung der prädizierten Verteilungen für die einzelnen Attribute erfolgt in Abhängigkeit der Szenarmodi und Skalenniveaus der repräsentierten Qualitäten. Im Allgemeinen werden von der Prädiktion die perzeptiven Attribute betroffen sein, nicht aber die semantischen. Für ein deduktives Attribut muss die Art und Weise seiner Herleitung individuell betrachtet werden. Nachfolgend werden Beispiele für die Prädiktion von Attributen unterschiedlicher Skalenniveaus gegeben. Die genannten Alterungsfaktoren entsprechen dabei den Alterungsfaktoren der durch das Attribut repräsentierten Qualität. Die Beispiele für eine Prädikation von nominalen und ordinalen Attributen gehen dabei über die Darstellungen der

Informationsverarbeitung in Vorarbeiten zur objektorientierten Umweltmodellierung hinaus.

Beispiel 1 (Verhältnisskaliertes Merkmal). Sei \mathbf{a}^c ein stetiges Attribut, welches ein verhältnisskaliertes Merkmal repräsentiert, und \mathbf{v} eine mittelwertfreie, normalverteilte Zufallsvariable mit Varianz σ_v^2 , welche das Rauschen bei der Prädiktion des Attributs \mathbf{a}^c beschreibt. Unter der Annahme, dass dieses Rauschen additiv in die Prädiktion eingeht und die Identität als Systemmodell verwendet wird, ergibt sich das Modell der Transitionswahrscheinlichkeit als die Normalverteilung [Ghe10a]

$$p(\mathbf{a}_k^c | \mathbf{a}_{k-1}^c, E_k^t) = \mathcal{N}(\mathbf{a}_k^c - \mathbf{a}_{k-1}^c, \sigma_v^2), \quad (5.12)$$

welche durch die Varianz des Rauschens charakterisiert wird. Zur Lösung der sich unter Verwendung dieses Modells ergebenden Chapman-Kolmogorov Gleichung (5.10) kann das Kalman-Filter genutzt werden. Unter den oben genannten Bedingungen lassen sich der Erwartungswert und die Varianz der auf den Zeitschritt t_k prädizierten Wahrscheinlichkeitsverteilung des Attributs \mathbf{a}_k^c dabei als

$$E(\mathbf{a}_k^c) = E(\mathbf{a}_{k-1}^c), \quad (5.13)$$

$$\text{Var}(\mathbf{a}_k^c) = \text{Var}(\mathbf{a}_{k-1}^c) + \sigma_v^2 \quad (5.14)$$

auf Basis der Kenngrößen der aktuellen Attributverteilung berechnen. Wird das Attribut \mathbf{a}_{k-1}^c hierbei durch eine Normalverteilung beschrieben, so ergibt sich das prädizierte Attribut \mathbf{a}_k^c ebenfalls als normalverteilt und ist durch die beiden berechneten Kenngrößen bereits vollständig spezifiziert. Handelt es sich bei der Verteilung von \mathbf{a}_{k-1}^c hingegen um ein durch eine Gaußmischverteilung beschriebenes Attribut, so muss obige Prädiktion für jede (normalverteilte) Komponente der Mischverteilung einzeln durchgeführt werden. Die Gewichte bleiben im Prädiktionsschritt unverändert. Durch die Alterung eines stetigen Attributs erhöht sich somit die Unsicherheit über seinen Wert, reflektiert durch die erhöhte Varianz seiner Verteilung. Der hierfür relevante Parameter, die Varianz des Rauschens σ_v^2 , ergibt sich in Abhängigkeit eines im Hintergrundwissen für die betroffene Qualität modellierten Alterungsfaktors.

Für diskrete Attribute ergibt sich das Transitionsmodell als eine Matrix, und die Chapman-Kolmogorov Gleichung (5.10) wird entsprechend durch die Multiplikation dieser Matrix mit der als Vektor dargestellten diskreten Verteilung des Attributs berechnet. Die Prädiktion entspricht dabei einem Schritt in einem Markov-Prozess, dessen Zustände von den möglichen Werten des diskreten Attributs dargestellt werden. Ein Systemrauschen kann für diskrete Attribute in der Form berücksichtigt werden, dass mit einer gewissen Übergangswahrscheinlichkeit p_v bei der Prädiktion von einem Attributwert auf einen anderen Attributwert gewechselt werden kann.

Beispiel 2 (Nominales Merkmal). Sei \mathbf{a}^d ein diskretes Attribut für ein nominales Merkmal mit den Werten $\{\omega_1, \omega_2, \dots, \omega_{n_a}\}$ und einem Alterungsfaktor β_a . Dann definiert

$$\underline{x}_k^a := \left[p(a^d = \omega_1), p(a^d = \omega_2), \dots, p(a^d = \omega_{n_a}) \right]^T \quad (5.15)$$

den Zustandsvektor für das diskrete Attribut im Zeitschritt t_k . Das Systemrauschen wird über die Wechselwahrscheinlichkeit p_v spezifiziert. Für nominale Merkmale wird dabei aufgrund der fehlenden Ordnungsrelation jeder Wechsel als gleich wahrscheinlich angenommen. Unter dieser Voraussetzung ergibt sich die Wechselwahrscheinlichkeit aus dem Alterungsfaktor β_a als $p_v := (1 - \beta_a)/(n_a - 1)$. Die zeitliche Fortschreibung des nominalen Attributs \mathbf{a}^d auf den Zeitschritt t_k ergibt sich dann als das Produkt

$$\underline{x}_k^a = \underbrace{\begin{pmatrix} \beta_a & p_v & \dots & \dots & p_v \\ p_v & \beta_a & p_v & \dots & p_v \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ p_v & \dots & p_v & \beta_a & p_v \\ p_v & \dots & \dots & p_v & \beta_a \end{pmatrix}}_{n_a \times n_a \text{ Transitionsmatrix}} \cdot \underline{x}_{k-1}^a \quad (5.16)$$

der auf β_a und p_v basierenden Transitionsmatrix mit dem bisherigen Zustandsvektor \underline{x}_{k-1}^a . Die Transitionsmatrix ist dabei symmetrisch. Ihre Zeilen- und Spaltensummen ergeben sich aufgrund der für p_v gewählten Definition als $\beta_a + (n_a - 1) \cdot p_v = \beta_a + (1 - \beta_a) = 1$. Dies bewirkt, dass mit \underline{x}_k^a wieder eine gültige, normierte Wahrscheinlichkeitsverteilung für \mathbf{a}^d entsteht.

Beispiel 3 (Ordinales Merkmal). Sei $\mathbf{\tilde{a}}^d$ ein diskretes Attribut für ein ordinales Merkmal mit Zustandsvektor $\underline{\tilde{x}}^a$ analog zu (5.15) und Alterungsfaktor $\tilde{\beta}_a$. Für ordinale Merkmale kann die zugrunde liegende Ordnungsrelation bei der Festlegung der Wahrscheinlichkeit eines Attributwert-Wechsels genutzt werden. Wird beispielsweise angenommen, dass der Wechsel eines Attributwerts immer nur zu einem nach der Ordnungsrelation benachbarten Attributwert möglich ist, so ergibt sich $\tilde{p}_v := (1 - \tilde{\beta}_a)/2$ als Basiswert der Wechselwahrscheinlichkeit. Dieser Basiswert wird in der Transitionsmatrix benachbarten Attributwerten zugeordnet, so dass sich für diese eine Bandstruktur mit zwei Nebendiagonalen ergibt. Eine Sonderstellung nehmen dabei der erste und letzte Attributwert in $\underline{\tilde{x}}^a$ ein, für welche nur ein benachbarter Wert existiert. Für diese kann als eine Art Randbedingung die Annahme getroffen werden, dass ein Verbleib beim aktuellen Attributwert entsprechend wahrscheinlicher ist, also z. B. der Wert $\beta_a^p := (\tilde{\beta}_a + \tilde{p}_v)$ genutzt werden, um in der Transitionsmatrix wieder Zeilen- und Spaltensummen mit Wert 1 zu erhalten. Unter diesen Annahmen ergibt sich die zeitliche Fortschreibung eines ordinalen Attributs auf den Zeitschritt t_k dann analog zum Vorgehen bei nominalen Attributen als das Produkt

$$\underline{\tilde{x}}_k^a = \underbrace{\begin{pmatrix} \beta_a^p & \tilde{p}_v & 0 & \dots & \dots & \dots & 0 \\ \tilde{p}_v & \tilde{\beta}_a & \tilde{p}_v & 0 & \dots & \dots & 0 \\ 0 & \tilde{p}_v & \tilde{\beta}_a & \tilde{p}_v & 0 & \dots & 0 \\ \vdots & \ddots & \ddots & \ddots & \ddots & \ddots & \vdots \\ 0 & \dots & 0 & \tilde{p}_v & \tilde{\beta}_a & \tilde{p}_v & 0 \\ 0 & \dots & \dots & 0 & \tilde{p}_v & \tilde{\beta}_a & \tilde{p}_v \\ 0 & \dots & \dots & \dots & 0 & \tilde{p}_v & \beta_a^p \end{pmatrix}}_{n_a \times n_a \text{ Transitionsmatrix}} \cdot \underline{\tilde{x}}_{k-1}^a \quad (5.17)$$

aus einer Transitionsmatrix und dem bisherigen Zustandsvektor $\underline{\tilde{x}}_{k-1}^a$.

5.1.4 Beobachtungsmodell

Die im Zeitschritt t_k an das objektorientierte Umweltmodell gelieferte Beobachtung \hat{y}_k kann aus einzelnen Messungen \hat{y}_k^j für die beobachteten Qualitäten einer Entität bestehen. Messungen enthalten dabei Messwerte zusammen mit einer Unsicherheitsangabe für die Messung. Für jede Qualität wird nun ein Messmodell benötigt, welches den Zusammenhang zwischen dem Wert einer Qualität und dem entsprechenden Messwert als eine mathematische Abbildung beschreibt. Bei der Beobachtung von Entitäten wird in der objektorientierten Umweltmodellierung allgemein von einer direkten Beobachtbarkeit der zu erfassenden Merkmale ausgegangen. Somit wird i. A. die Identitätsfunktion als Messabbildung genutzt.

Für einen Repräsentanten \mathbf{r} beschreibt das Beobachtungsmodell die Wahrscheinlichkeitsverteilung, unter welcher in einer Beobachtung der repräsentierten Entität bei gegebenen Messunsicherheiten entsprechende Merkmalswerte beobachtet werden können. Das Beobachtungsmodell eines Repräsentanten ergibt sich im Zeitschritt t_k als das Produkt [Ghe10a, Bau10]

$$p(\underline{\hat{y}}_k \mid \underline{\mathbf{a}}_k^r, E_k^r) = \prod_{i=1}^n p(\hat{y}_k^{j_i} \mid a_k^i, E_k^r) \quad (5.18)$$

aus attributsabhängigen Messmodellen, die durch die individuellen Messmodelle $p_i(\hat{y}_k \mid a_k)$ der Attribute \mathbf{a}_k^i des Repräsentanten beschrieben werden können. Die Zuordnung eines die Qualität i repräsentierenden Attributs \mathbf{a}_k^i zur Messung $\hat{y}_k^{j_i}$ der entsprechenden Qualität erfolgt dabei über den Index j_i . Die konkrete Form der individuellen Messmodelle $p_i(\hat{y}_k \mid a_k)$ hängt vom Skalenniveau der durch \mathbf{a}_k^i repräsentierten Qualität ab. Nachfolgend werden zu unterschiedlichen Skalenniveaus wiederum Beispiele für Messmodelle genannt. Die Darstellung für nominale und ordinale Attribute geht dabei, ähnlich wie in den zuvor genannten Beispielen für Transitionsmodelle, über die in Vorarbeiten zur objektorientierten Umweltmodellierung dargestellten Informationen hinaus.

Beispiel 4 (Verhältnisskaliertes Merkmal). Sei \mathbf{a}^c ein stetiges Attribut, welches ein verhältnisskaliertes Merkmal beschreibt. Für das Merkmal wird eine direkte Beobachtbarkeit angenommen, mit der Identitätsfunktion als Messabbildung, sowie eine Messunsicherheit, welche in Form eines additiven mittelwertfreien Gauß'sches Rauschens $\boldsymbol{\gamma}_k$ mit Varianz $\sigma_{\boldsymbol{\gamma},k}^2$ beschrieben werden kann. Dann ergibt sich im Zeitschritt t_k das Messmodell

$$\mathbf{y}_k = \mathbf{a}_k^c + \boldsymbol{\gamma}_k, \tag{5.19}$$

wobei das Attribut \mathbf{a}_k^c hier stellvertretend für das dargestellte Merkmal steht, sowie der funktionale Zusammenhang

$$p(\hat{y}_k | \mathbf{a}_k^c) = \mathcal{N}(\hat{y}_k - \mathbf{a}_k^c, \sigma_{\boldsymbol{\gamma},k}^2) \tag{5.20}$$

in Analogie zum Transitionsmodell (5.12).

Beispiel 5 (Nominales Merkmal). Sei \mathbf{a}^d ein diskretes Attribut für ein nominales Merkmal mit Werten aus $\{\omega_1, \omega_2, \dots, \omega_{n_a}\}$. Weiterhin beschreibe σ_d die Messabweichung für das durch \mathbf{a}^d repräsentierte Merkmal in Form einer prozentualen Sicherheit, den realen Wert des Merkmals auch tatsächlich zu beobachten. Dann beschreibt $p_\gamma = (1 - \sigma_d)/(n_a - 1)$ die Wahrscheinlichkeit, einen abweichenden Wert zu beobachten. Auch für nominale Attribute wird grundsätzlich die Identitätsfunktion zur Beschreibung des deterministischen Zusammenhangs zwischen Merkmalswert und Messwert angenommen. Stellt man \mathbf{a}^d wie in (5.15) als Zustandsvektor \underline{x}_k^a dar, so ergibt sich im Zeitschritt t_k der funktionale Zusammenhang

$$\underline{y}_{-k}^a = \underbrace{\begin{pmatrix} \sigma_d & p_\gamma & \dots & \dots & p_\gamma \\ p_\gamma & \sigma_d & p_\gamma & \dots & p_\gamma \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ p_\gamma & \dots & p_\gamma & \sigma_d & p_\gamma \\ p_\gamma & \dots & \dots & p_\gamma & \sigma_d \end{pmatrix}}_{:= \mathbf{H}, n_a \times n_a \text{ Messmatrix}} \cdot \underline{x}_k^a \tag{5.21}$$

zwischen dem Wahrscheinlichkeitsvektor \underline{y}_{-k}^a der Messwerte für das Merkmal zu \mathbf{a}^d als Produkt aus Messmatrix \mathbf{H} und aktuellem Zustandsvektor \underline{x}_k^a .

Beispiel 6 (Ordinales Merkmal). Für ein diskretes Attribut mit ordinalem Merkmal besitzt das Messmodell die gleiche Form wie (5.21), allerdings ist die Messmatrix \mathbf{H} als eine Bandmatrix strukturiert (analog zur Matrix in (5.17)). Dabei nehmen die beiden Nebendiagonalen den Wert $\tilde{p}_\gamma = (1 - \sigma_d)/2$ an, welcher auch als zusätzlicher Summand in den beiden Randelementen der Hauptdiagonalen auftritt.

Als Erweiterung des Messmodells (5.18) eines Repräsentanten kann die Möglichkeit berücksichtigt werden, dass sich bei einer konkreten Beobachtung verschiedene Untermengen $\mathcal{M}_k \subseteq \{1, 2, \dots, n\}$ von enthaltenen Merkmalen i ergeben, z. B. in Abhängigkeit des Typs c^r der beobachteten Entität [Ghe10a, Bau10]. Dies liegt darin begründet, dass zu verschiedenen Entitäten nicht in allen Situationen für die grundsätzlich beobachtbaren Merkmale auch tatsächliche Werte bestimmt werden können. Davon kann z. B. die Form eines Gegenstands betroffen sein, wenn dieser teilweise verdeckt oder zu weit entfernt ist. Unter Inbetrachtung dieser Möglichkeit erweitert sich das Beobachtungsmodell [Ghe10a, Bau10] auf

$$p(\underline{y}_k | \underline{a}_k^r, E_k^r) = \prod_{j=1}^s p(\hat{y}_k^j | a_k^{i_j}, E_k^r) \cdot p(\mathcal{M}_k | c_k^r), \quad \mathcal{M}_k = \bigcup_j i_j, \quad (5.22)$$

wobei i_j hier nun das zur Messung korrespondierende Attribut indiziert.

Nachfolgend wird beschrieben, wie die Informationsalterung sowie die Aktualisierungen von Repräsentanten aufgrund neuer Beobachtungen in Form einer rekursiven Zustandsschätzung durchgeführt werden können. Die Informationsalterung erfolgt dabei im Sinne einer Prädiktion unter Verwendung der Transitionsmodelle. Die Aktualisierung erfolgt im Sinne einer Filterung unter Verwendung der Messmodelle.

5.2 Datenassoziation

Die Datenassoziation löst das Problem der Zuordnung von Entitätsbeobachtungen zu Repräsentanten im Weltmodell und ist somit ein integraler Bestandteil der probabilistischen Informationsverarbeitung im objektorientierten Umweltmodell. Aufgrund der Komplexität des Themas wird die Datenassoziation in einem eigenen Abschnitt beschrieben.

Mögliche Ansätze Als Ergebnis der Datenassoziation kann entweder eine deterministische Zuordnung jeder Beobachtung eines Zeitschritts zu genau einem Repräsentanten erfolgen, oder eine probabilistische Zuordnung, in welcher die Beziehung zwischen Beobachtungen und Repräsentanten in Form einer gemeinsamen Wahrscheinlichkeitsverteilung beschrieben wird. Erfolgt eine deterministische Zuordnung, so kann auf Basis dieser Zuordnung jeder Repräsentant anschließend unabhängig durch die ihm zugeordneten Beobachtungen aktualisiert werden. Gängige Methoden [Rus10] zur Erstellung einer deterministischen Zuordnung sind Nächste-Nachbar-Verfahren oder der Kuhn-Munkres-Algorithmus, auch bekannt als die Ungarische Methode [Kuh55]. Für eine probabilistische Zuordnung lassen sich unterschiedlich komplexe Ansätze und Verfahren mit verschiedenen Annahmen unterscheiden. Eine einfachere probabilistische Zuordnung erlaubt zunächst die Möglichkeit, einem Repräsentanten nicht nur eine Beobachtung zuzuordnen, sondern mehrere Beobachtungen anteilig. Für die Aktualisierung des Repräsentanten werden dann alle zugeordneten Beobachtungen entsprechend ihres Anteils verwendet. Dieses Vorgehen entspricht dem Ansatz des probabilistischen Datenassoziations-Filters PDAF¹ [Bar09]. Ein Problem kann bei diesem Ansatz auftreten, wenn eine Beobachtung mehreren Repräsentanten zugleich zugeordnet wird, ohne dass diese Mehrfachzuordnung entsprechend berücksichtigt wird. Zur Lösung dieses Problems kann der Ansatz des gemeinsamen probabilistischen Datenassoziations-Filters JPDAF² [Bar09] genutzt werden. Unter

¹ Englisch: Probabilistic Data Association Filter (PDAF)

² Englisch: Joint Probabilistic Data Association Filter (JPDAF)

Anwendung dieses Ansatzes wird dann zusätzlich darauf geachtet, dass für Beobachtungen, die mehreren Repräsentanten anteilig zugeordnet werden, ihr Gesamtanteil in Summe den Wert 1 nicht überschreitet. Ein weiteres Vorgehen stellt ein sog. Multi-Hypothesen-Ansatz dar, in welchem verschiedene mögliche Zuordnungen von Beobachtungen zu Repräsentanten über mehrere Zeitschritte hinweg verfolgt werden, um im Nachhinein und mit mehr Informationen die beste Zuordnung auswählen zu können.

Vorgehen im objektorientierten Umweltmodell Erfolgt eine deterministische Zuordnung von Beobachtungen zu Repräsentanten im Weltmodell, so kann die Datenassoziation als eigenständiger Verarbeitungsschritt vor der Aktualisierung von Repräsentanten ausgeführt werden, wie im allgemeinen Verarbeitungsschema dargestellt. Erfolgt dagegen eine probabilistische Zuordnung, so kann es notwendig bzw. sinnvoll sein, einen integrierten Ansatz zu verwenden, in welchem die Assoziation und Aktualisierung von Repräsentanten, ggf. sogar schon die Prädiktion, zusammen in einem Verarbeitungsschritt durchgeführt werden.

Ein solch integrierter Ansatz für die Datenassoziation im objektorientierten Umweltmodell wird in Vorarbeiten von Baum et al. [Bau10] beschrieben. Dabei wird davon ausgegangen, dass ein kognitives System mittels Sensoren eine Szene beobachtet und dabei pro diskretem Zeitschritt genau die Merkmale einer Entität erfasst und als Beobachtung an das Weltmodell geliefert werden. Das Problem der Datenassoziation besteht nun daraus, die gelieferten Messergebnisse einem Repräsentanten im Weltmodell zuzuordnen. Das in [Bau10] vorgeschlagene Vorgehen für das objektorientierte Umweltmodell entspricht dabei dem Ansatz des gemeinsamen probabilistischen Datenassoziations-Filters JPDAF mit der zusätzlichen Einschränkung, dass pro Zeitschritt nur eine Beobachtung vorliegt. Das Weltmodell wird für die Datenassoziation als die Menge \mathcal{R} der in ihm enthaltenen Repräsentanten aufgefasst werden. Sind zum Zeitpunkt der Beobachtung $|\mathcal{R}|$ Repräsentanten im Weltmodell enthalten, so muss zur Lösung des Datenassoziationsproblems eine diskrete Zufallsvariable \mathbf{d} über allen Repräsentanten aus \mathcal{R} bestimmt werden. Jedem $r \in \mathcal{R}$ wird dabei die Wahrscheinlichkeit $p(\mathbf{d} = r)$

zugeordnet, dass durch die Beobachtung die vom Repräsentanten dargestellte Entität erfasst wurde, vorausgesetzt der Repräsentant existiert zu diesem Zeitpunkt (dargestellt als das Ereignis $e^r = 1$).

Struktur des Abschnitts Nachfolgend wird das grundlegende Vorgehen zur Datenassoziation im objektorientierten Umweltmodell aus Vorarbeiten vorgestellt. In Abschnitt 5.2.1 wird dabei auf die Aktualisierung von deskriptiven Attributen eingegangen. In Abschnitt 5.2.2 wird die Berechnung der Zuordnungswahrscheinlichkeit beschrieben, welche gemeinsam mit der Aktualisierung der Existenzwahrscheinlichkeiten der Repräsentanten erfolgt. Anschließend werden in den nachfolgenden drei Abschnitten verschiedene eigene Erweiterungen dieser probabilistischen Datenassoziation für die objektorientierte Umweltmodellierung vorgeschlagen (5.2.3, 5.2.4) und demonstriert (5.2.5), basierend auf einer Untersuchung des bisherigen Vorgehens (5.2.3).

5.2.1 Zustandsschätzung zur Beobachtungsintegration

Wenn in einem Zeitschritt t_k eine neue Beobachtung $\underline{\hat{y}}_k$ an das Weltmodell geliefert wird, wird das allgemeine Prädiktor-Korrektor Schema der Bayes'schen Zustandsschätzung zur Aktualisierung der gespeicherten Repräsentanten genutzt. Dazu werden zunächst in einem Prädiktionsschritt die Existenzwahrscheinlichkeiten aller Repräsentanten auf den Zeitschritt t_k zeitlich fortgeschrieben, wie in Gleichung (5.8) beschrieben. Gleichzeitig werden die Attributverteilungen der Repräsentanten zeitlich fortgeschrieben, unter der Annahme, dass der entsprechende Repräsentant weiterhin im Weltmodell existiert, ansonsten unabhängig vom konkreten Wert der Existenzwahrscheinlichkeit. Dazu wird Gleichung (5.10) verwendet.

Aktualisierung von deskriptiven Attributen

Nach dem Prädiktionsschritt folgt der Filterschritt, in welchem auch die Assoziation der Beobachtung mit den entsprechenden Repräsentanten erfolgt [Bau10]. Zur Berechnung der aktualisierten Verteilung $p(a_k^i | E_k^r, \underline{\hat{y}}_{1:k})$ eines

deskriptiven Attributs \mathbf{a}_k^i des Repräsentanten r wird der Filterschritt

$$p(\mathbf{a}_k^i | E_k^r, \underline{\hat{y}}_{1:k}) = \sum_{d_k} p(\mathbf{a}_k^i | E_k^r, \underline{\hat{y}}_{1:k}, d_k) \cdot p(d_k | E_k^r, \underline{\hat{y}}_{1:k}) \quad (5.23)$$

durchgeführt. Der Aktualisierungsterm $p(\mathbf{a}_k^i | E_k^r, \underline{\hat{y}}_{1:k}, d_k)$ wird dabei mit dem Faktor $p(d_k | E_k^r, \underline{\hat{y}}_{1:k})$ gewichtet [Bau10]. Dieser gibt die Wahrscheinlichkeitsverteilung für die Assoziation der Beobachtung $\underline{\hat{y}}_k$ zu den Repräsentanten $r \in \mathcal{R}$ an, basierend auf der Historie der bisherigen Beobachtungen $\underline{\hat{y}}_{1:k}$. Für den Fall $D_k^r := (d_k = r)$, dass die Beobachtung zum betrachteten Repräsentanten r korrespondiert, kann der Aktualisierungsterm als die übliche A-posteriori-Verteilung der Bayes'schen Zustandsschätzung berechnet werden als

$$p(\mathbf{a}_k^i | E_k^r, \underline{\hat{y}}_{1:k}, D_k^r) = \frac{1}{z} \cdot \underbrace{p(\underline{\hat{y}}_k^{j_i} | \mathbf{a}_k^i, E_k^r, D_k^r)}_{\text{Likelihood}} \cdot \underbrace{p(\mathbf{a}_k^i | E_k^r, \underline{\hat{y}}_{1:k-1}, D_k^r)}_{\text{A-priori-Verteilung}} \cdot \quad (5.24)$$

Hierbei stellt z eine Normierungskonstante dar. Weiterhin können, unter der gegebenen Bedingung D_k^r , als Likelihood das Messmodell $p_i(\underline{\hat{y}}_k | \mathbf{a}_k)$ des betrachteten Attributs \mathbf{a}_k^i genutzt werden sowie als a-priori Verteilung das Ergebnis des Prädiktionsschritt (5.10). Je nach Skalenniveau des Attributs \mathbf{a}_k^i ist hierbei ein unterschiedliches Vorgehen notwendig. Dies wird nachfolgend als kurzer Einschub anhand von zwei Beispielen dargestellt, bevor auf den Fall $\bar{D}_k^r := (d_k \neq r)$ eingegangen wird.

Beispiel 7 (Stetiges Attribut). Sei \mathbf{a}^c ein stetiges Attribut mit Messmodell (5.20). Ist \mathbf{a}^c normalverteilt, so kann zur Berechnung der aktualisierten Attributverteilung das wohlbekannte Kalman-Filter eingesetzt werden. Wird \mathbf{a}^c hingegen durch eine Gaußmischverteilung beschrieben, so muss zunächst jede (normalverteilte) Komponente einzeln aktualisiert werden, und anschließend eine Aktualisierung der Gewichte durchgeführt werden.

Beispiel 8 (Diskretes Attribut). Sei \mathbf{a}^d ein diskretes Attribut mit Werten aus $\{\omega_1, \omega_2, \dots, \omega_{n_a}\}$ und \underline{x}_k^a der entsprechende Zustandsvektor für \mathbf{a}^d anhand

von (5.15). Sei weiterhin ein Messwert $\hat{y}_k = \omega_i$ für \mathbf{a}^d sowie dessen Sicherheit σ_d in einer Beobachtung gegeben und \mathbf{H} die dem Skalenniveau des durch \mathbf{a}^d repräsentierten Merkmals entsprechende Messmatrix (wie z. B. in (5.21) für nominale Merkmale definiert). Zur Aktualisierung des Attributs werden dann all diejenigen Beobachtungswahrscheinlichkeiten $p(\hat{y}_k = \omega_i | \mathbf{a}^d)$ zum gegebenen Messwert ω_i aus \mathbf{H} ausgewählt (hier notiert als $\mathbf{H}_{|\hat{y}_k=\omega_i}$) und als Diagonalmatrix dargestellt. Für das aktualisierte Attribute $\tilde{\mathbf{a}}^d$ ergibt sich dann die Wahrscheinlichkeitsverteilung

$$\underline{\tilde{x}}_k^a = \text{Diag}(\mathbf{H}_{|\hat{y}_k=\omega_i}) \cdot \underline{x}_k^a \quad (5.25)$$

als Produkt dieser Diagonalmatrix mit dem Zustandsvektor \underline{x}_k^a .

Neben $D_k^r := (d_k = r)$ muss bei der Aktualisierung von deskriptiven Attributen in (5.23) auch der Fall betrachtet werden, dass die Beobachtung \hat{y}_k nicht dem betrachteten Repräsentanten r zugeordnet ist. Für alle Fälle $\bar{D}_k^r := (d_k \neq r)$ hat die Beobachtung \hat{y}_k dabei keinen Einfluss auf die Attribute \mathbf{a}_k^i von r . Nach Vermaak et al. [Ver05], auf welche sich [Bau10] bezieht, kann in diesem Fall die entsprechende Likelihood $p(\hat{y}_k | \mathbf{a}_k^i, \bar{D}_k^r)$ als proportional zu 1 angenommen werden. Damit ergibt sich als Aktualisierungsterm direkt die unveränderte A-priori-Verteilung

$$p(\mathbf{a}_k^i | E_k^r, \underline{\hat{y}}_{1:k}, \bar{D}_k^r) = p(\mathbf{a}_k^i | E_k^r, \underline{\hat{y}}_{1:k-1}) . \quad (5.26)$$

Der Filterschritt für deskriptive Attribute (5.23) kann somit als die Summe

$$\begin{aligned} \frac{1}{z} \cdot p(\hat{y}_k^j | \mathbf{a}_k^i, E_k^r, D_k^r) \cdot p(\mathbf{a}_k^i | E_k^r, \underline{\hat{y}}_{1:k-1}, D_k^r) \cdot p(D_k^r | E_k^r, \underline{\hat{y}}_{1:k}) \\ + p(\mathbf{a}_k^i | E_k^r, \underline{\hat{y}}_{1:k-1}, \bar{D}_k^r) \cdot p(\bar{D}_k^r | E_k^r, \underline{\hat{y}}_{1:k}) \end{aligned} \quad (5.27)$$

beschrieben werden, unter Angabe aller formal benötigter Bedingungen.

Zusammengefasst und vereinfacht dargestellt ergibt sich der Filterschritt zur Aktualisierung eines deskriptiven Attributs \mathbf{a}_k^i somit als

$$p(\mathbf{a}_k^i | E_k^r, \underline{\hat{y}}_{1:k}) = \underbrace{p(\mathbf{a}_k^i | E_k^r, \underline{\hat{y}}_{1:k-1})}_{\text{A-priori-Verteilung}} \left(\frac{1}{Z} \cdot p_k^{dr} \cdot \underbrace{p(\hat{y}_k^{ji} | \mathbf{a}_k^i, E_k^r, D_k^r)}_{\text{Likelihood}} + (1 - p_k^{dr}) \right), \quad (5.28)$$

mit der Abkürzung $p_k^{dr} := p(D_k^r | E_k^r, \underline{\hat{y}}_{1:k})$. Anschaulich gesprochen bedeutet dies, dass eine gegebene Beobachtung \hat{y}_k je nach Verteilung der Assoziationswahrscheinlichkeit $p(d_k | \underline{e}_k, \underline{\hat{y}}_{1:k})^1$ anteilig zur Aktualisierung von unterschiedlichen Repräsentanten beitragen kann – nämlich allen Repräsentanten r mit $p(D_k^r | \underline{e}_k, \underline{\hat{y}}_{1:k}) \neq 0$. Dies entspricht somit, wie bereits einleitend erwähnt, dem grundsätzlichen Vorgehen des gemeinsamen probabilistischen Datenassoziations-Filters JPDAF für den Spezialfall, dass jeweils nur ein Objekt pro Zeitschritt beobachtet wird. Alle anderen Repräsentanten im Weltmodell werden nicht aktualisiert, unabhängig davon jedoch zeitlich fortgeschrieben.

5.2.2 Assoziation- und Existenzwahrscheinlichkeit

Die Berechnung der Assoziationswahrscheinlichkeit p_k^{dr} in (5.28) erfolgt in einem Schritt mit der Aktualisierung der Existenzwahrscheinlichkeiten $p(\underline{e}_k | \underline{\hat{y}}_{1:k})$ [Bau10]. Dazu wird die gemeinsame Verteilung von Existenz- und Assoziationswahrscheinlichkeiten $p(\underline{e}_k, d_k | \underline{\hat{y}}_{1:k})$ genutzt. Für einen Repräsentanten r kann dessen Existenzwahrscheinlichkeit dabei durch Marginalisierung der gemeinsamen Verteilung über die Existenzvariablen der restlichen Repräsentanten und die Assoziationsvariable berechnet

¹ Mit $\underline{e}_k := [e_k^{r_1}, e_k^{r_2}, \dots, e_k^{r_{|R|}}]^T$

werden als

$$p(e_k^{r_i}, d_k | \underline{\hat{y}}_{1:k}) = \sum_{e_k^{r_1}, e_k^{r_2}, \dots, e_k^{r_{i-1}}, e_k^{r_{i+1}}, \dots, e_k^{r_{|R|}}} p(\underline{e}_k, d_k | \underline{\hat{y}}_{1:k}) , \quad (5.29)$$

$$p(e_k^{r_i} | \underline{\hat{y}}_{1:k}) = \sum_{d_k} p(e_k^{r_i}, d_k | \underline{\hat{y}}_{1:k}) . \quad (5.30)$$

Die Assoziationswahrscheinlichkeit eines Repräsentanten r ergibt sich auf Basis der marginalisierten Verteilungen als die bedingte Wahrscheinlichkeit

$$p_k^{dr} = \frac{p(E_k^r, D_k^r | \underline{\hat{y}}_{1:k})}{p(E_k^r | \underline{\hat{y}}_{1:k})} . \quad (5.31)$$

Aktualisierung von Existenz- und Assoziationswahrscheinlichkeit

Der für das objektorientierte Umweltmodell vorgeschlagene Ansatz zur Datenassoziation [Bau10] wird als Spezialfall des Vorgehens von Horridge und Maskell [Hor09] sowie Vermaak et al. [Ver05] ausgewiesen, in welchem die gleichzeitige Verfolgung mehrerer Objekte basierend auf einer Menge von Sensormessungen pro Zeitschritt betrachtet wird. Ziel ist dabei, jedem Objekt die von ihm erzeugte Messung zuzuordnen, falls dieses im betrachteten Zeitschritt beobachtet wurde. Dazu wird je Objekt eine Assoziationsvariable über der Menge der Sensormessungen pro Zeitschritt eingeführt. Bei der Datenassoziation im OOWM liegen geänderte Bedingungen vor. Der hauptsächlichste Unterschied besteht darin, dass pro Zeitschritt nur die Beobachtung einer einzelnen Entität betrachtet wird. Das Problem der Datenassoziation besteht nun darin, diese Beobachtung einem Repräsentanten im Weltmodell zuzuordnen. Für die objektorientierte Umweltmodellierung wurden in [Bau10] Assoziationsvariablen \mathbf{d}_k eingeführt, welche im Unterschied zum Vorgehen in [Hor09] bzw. [Ver05] aber nun über der Menge der Repräsentanten definiert sind. Dieser grundlegende Unterschied muss in den nachfolgenden Ausführungen in Betracht gezogen werden.

Die gemeinsame Verteilung von Existenz- und Assoziationswahrscheinlichkeiten für den Zeitschritt t_k ergibt sich anhand des Satzes von Bayes als das Produkt [Bau10, Hor09]

$$p(\underline{e}_k, d_k | \underline{y}_{1:k}) = \frac{1}{z_e} \cdot \underbrace{p(\underline{y}_k | \underline{e}_k, d_k, \underline{y}_{1:k-1})}_{\text{Prädizierte Messung}} \cdot \underbrace{p(\underline{e}_k, d_k | \underline{y}_{1:k-1})}_{\text{Priore Verteilung}} \quad (5.32)$$

einer Prädiktion der Messung und der prioren Existenz- und Assoziationswahrscheinlichkeit, mit Normierungskonstante z_e . Die prädizierte Messung beschreibt dabei die erwartete Verteilung der Messung bzw. die Wahrscheinlichkeit einer konkreten Messung \underline{y}_k , ausgehend von einer gegebenen Zuordnung D_k^r der Messung zu einem als existent angenommenen Repräsentanten r und dessen auf den aktuellen Zeitschritt t_k prädizierten Zustand. Die Berechnung der prädizierten Messverteilung erfolgt als Chapman-Kolmogorov Integral durch die Einführung des Zustands des betroffenen Repräsentanten r [Hor09]. Für $d_k = r$ ergibt sich somit

$$p(\underline{y}_k | \underline{e}_k, D_k^r, \underline{y}_{1:k-1}) = \int \underbrace{p(\underline{y}_k | \underline{a}_k^r, E_k^r, D_k^r)}_{\text{Messmodell für } r} \cdot \underbrace{p(\underline{a}_k^r | E_k^r, \underline{y}_{1:k-1})}_{\text{Prädizierter Zustand}} d\underline{a}_k^r, \quad (5.33)$$

für den Fall, dass der betroffene Repräsentant auch existiert, also das Ereignis E_k^r als eine Komponente im Vektor \underline{e}_k enthalten ist. Ein solcher Vektor wird nachfolgenden abkürzend als \underline{e}_k^r notiert. Nichtexistierende Repräsentanten im Falle der Parameterkombination D_k^r und \bar{E}_k^r tragen nach [Ver05] und [Hor09] nicht zur Messverteilung bei, so dass

$$p(\underline{y}_k | \underline{e}_k^r, D_k^r, \underline{y}_{1:k-1}) = 0, \quad (5.34)$$

wobei der Vektor \underline{e}_k^r hier abkürzend den Fall beschreibt, dass explizit das Ereignis \bar{E}_k^r im Vektor \underline{e}_k beschrieben ist.

Die priore Existenz- und Assoziationswahrscheinlichkeit kann als das Produkt [Bau10]

$$p(\underline{e}_k, d_k | \underline{y}_{1:k-1}) = \underbrace{p(d_k | \underline{e}_k, \underline{y}_{1:k-1})}_{\text{Priore Assoziation}} \cdot \underbrace{p(\underline{e}_k | \underline{y}_{1:k-1})}_{\text{Präd. Existenz}} \quad (5.35)$$

aus prädierten Existenzwahrscheinlichkeiten und einer Verteilung der prioren Assoziationswahrscheinlichkeiten berechnet werden.

Priore Assoziationswahrscheinlichkeit

Für diese priore Assoziationsverteilung können nun verschiedene Modelle angenommen werden. Nach Horridge und Maskell [Hor09] werden beispielsweise existierende Objekte ($e_k = 1$) mit einer gewissen Wahrscheinlichkeit durch Messungen detektiert. Nichtexistierende Objekte ($e_k = 0$) werden dagegen mit Wahrscheinlichkeit 1 nicht detektiert, also mit keiner Messung assoziiert. Die Assoziationsvariablen pro Objekt ergeben sich in Abhängigkeit von der Objektexistenz dann entsprechend dieses Modells. Für die objektorientierte Umweltmodellierung wird in [Bau10] ein ähnliches Modell vorgeschlagen, welches die Existenzvariable e_k^r eines einzelnen Repräsentanten r mit der Wahrscheinlichkeit der Belegung der Assoziationsvariable $d_k = r$ in Verbindung setzt, und dabei das skalare Transitionsmodell

$$p(D_k^r | E_k^r) = p_T \quad (5.36)$$

$$p(D_k^r | \bar{E}_k^r) = p_F \quad (5.37)$$

nutzt, welches die Beobachtung einer existierenden Entität („Treffer“) durch die Wahrscheinlichkeit p_T modelliert. Dabei ist die Wahrscheinlichkeit einer falschen Zuordnung, d. h. die Zuordnung einer Beobachtung zu einer nicht-existierenden Entität, explizit mit einer Wahrscheinlichkeit p_F modelliert. Da im objektorientierten Umweltmodell die Assoziationsvariable über der Menge der Repräsentanten definiert ist, muss das skalare Modell $p(d_k | e_k^r)$ auf ein vektorwertiges Modell $p(d_k | \underline{e}_k)$ erweitert werden, um in Gleichung (5.35) genutzt werden zu können. Dabei ist zu beachten, dass im objektorientierten Umweltmodell das Ereignis $d_k \neq r_i$ gleichbedeutend dazu ist, dass

$p(d_k = r_j) > 0$ für mindestens einen anderen Repräsentanten r_j mit $j \neq i$ gelten muss.

5.2.3 Erweiterung und Untersuchung der Datenassoziation

Ein vektorwertiges Modell $p(d_k | \underline{e}_k)$ für die priore Assoziationswahrscheinlichkeit wird in Vorarbeiten zur objektorientierten Umweltmodellierung nicht diskutiert. Nachfolgend werden daher zwei eigene mögliche Ansätze für solche Modelle vorgestellt, die im Rahmen dieser Arbeit entwickelt wurden. Unter Verwendung dieser Modelle wird daraufhin der bisher vorgestellte Ansatz zur Datenassoziation im objektorientierten Umweltmodell detailliert untersucht.

Zunächst muss für vektorwertige Modelle beachtet werden, dass nach (5.34) prädierte Messungen nur dann nicht verschwinden, wenn der aufgrund der Assoziation D_k^r durch die Messung betroffene Repräsentant r auch existiert, also \underline{e}_k^r gilt (E_k^r ist in \underline{e}_k gegeben). Dies bedeutet im Speziellen, dass die Werte von bedingten Wahrscheinlichkeiten der Form $p(D_k^r | \underline{e}_k^r)$ in jedem vektorwertigen Modell keine Relevanz bei der Berechnung der gemeinsamen posterioren Existenz- und Assoziationswahrscheinlichkeit haben (wegen Auslöschung) und somit ignoriert werden können.

Ein erstes einfaches Modell für $p(d_k | \underline{e}_k)$ ergibt sich unter diesen Voraussetzungen, indem man analog zum Vorgehen in [Hor09] bei der prioren Assoziation keine nichtexistierenden Entitäten berücksichtigt, als

$$p(D_k^r | \underline{e}_k^r) := p_T, \quad p(D_k^r | \bar{\underline{e}}_k^r) := 0. \quad (5.38)$$

Dieses Modell beschreibt, dass jede in einem Zeitschritt existierende Entität mit der gleichen Wahrscheinlichkeit p_T beobachtet werden kann. Als nichtexistiert angenommene Entitäten können nicht beobachtet werden. Die Wahrscheinlichkeit p_T ergibt sich dabei aus der Anzahl der im Zeitschritt existierenden Repräsentanten. Ein zweites, komplexeres Modell für die priore Assoziationswahrscheinlichkeit kann dagegen die

Existenzwahrscheinlichkeiten \underline{e}_k aller Repräsentanten für die Assoziation berücksichtigen. Dies kann erreicht werden, indem Fehldetektionen im Falle von E_k^r dadurch berücksichtigt, dass mit einer bedingten Wahrscheinlichkeit $p_F := p(D_k^r | e_k^{rj} = 1, E_k^r)$ für als existent angenommene Repräsentanten $r_j \neq r$ die Beobachtung dem Repräsentanten r zugeordnet wird, obwohl eigentlich der Repräsentant r_j beobachtet wurde (genauer gesagt, die durch ihn repräsentierte Entität). Dieses Modell beschreibt also nun, dass wenn eine Entität existiert, diese mit einer Wahrscheinlichkeit größer als p_T beobachtet werden kann (und sonst weiterhin nicht). Beschreibt $\underline{e}_k^{r_i}$ im obigen Sinne das Ereignis

$$\underline{e}_k^{r_i} := [e_k^{r_1}, e_k^{r_2}, \dots, e_k^{r_{i-1}}, E_k^{r_i}, e_k^{r_{i+1}}, \dots, e_k^{r_{|\mathcal{R}|}}]^T, \quad (5.39)$$

so kann unter Nutzung der Iverson Notation¹ $[E_k^{r_j}]$ als Modell dieser komplexeren prioren Assoziation die $1 \times |\mathcal{R}|$ -Transitionsmatrix

$$\underbrace{[[E_k^{r_1}] \cdot p_F, [E_k^{r_2}] \cdot p_F, \dots, [E_k^{r_{i-1}}] \cdot p_F, p_T, [E_k^{r_{i+1}}] \cdot p_F, \dots, [E_k^{r_{|\mathcal{R}|}}] \cdot p_F]}_{=: p(d_k=r_i | \underline{e}_k^{r_i})} \quad (5.40)$$

angegeben werden. Unter Verwendung dieses Modells kann nun die Berechnung der gemeinsamen Existenz- und Assoziationswahrscheinlichkeit in (5.32) konkretisiert werden. Für den Fall $\underline{e}_k^{r_i}$ ergibt sich diese gemeinsame Wahrscheinlichkeit durch Multiplikation obiger Transitionsmatrix mit dem Vektor $[p(E_k^{r_1} | \underline{y}_{1:k-1}), p(E_k^{r_2} | \underline{y}_{1:k-1}), \dots, p(E_k^{r_{|\mathcal{R}|}} | \underline{y}_{1:k-1})]^T$ der prädiagnostizierten Existenzwahrscheinlichkeiten $E_k^{r_j}$ als

$$p(\underline{e}_k^{r_i}, D_k^{r_i} | \underline{y}_{1:k}) \sim p_k^{y_{r_i}} \cdot \left(p_T \cdot p(E_k^{r_i} | \underline{y}_{1:k-1}) + \sum_{r_j \neq r_i} [E_k^{r_j}] \cdot p_F \cdot p(E_k^{r_j} | \underline{y}_{1:k-1}) \right), \quad (5.41)$$

¹ Für eine Aussage S wird der Ausdruck $[S]$ dabei zu 1 ausgewertet, falls die Aussage wahr ist, anderenfalls zu 0.

wobei $p_k^{y_{r_i}} = p(\hat{y}_k | E_k^{r_i}, D_k^{r_i})$ abkürzend die Wahrscheinlichkeit der Beobachtung \hat{y}_k im prädizierten Messmodell von r_i beschreibt. Anderenfalls gilt:

$$p(\underline{e}_k^{r_i}, D_k^{r_i} | \underline{\hat{y}}_{1:k}) = 0 . \quad (5.42)$$

Eigenschaften der gemeinsamen Wahrscheinlichkeitsverteilung

Wie oben erwähnt wird für das objektorientierte Umweltmodell in Vorarbeiten [Bau10] angenommen, dass pro Zeitschritt immer nur maximal die Beobachtung einer Entität verarbeitet wird – im Gegensatz zur Erfassung aller relevanten Objekte pro Zeitschritt im Ansatz von Horridge und Maskell [Hor09]. Weiterhin aktualisiert der bisher vorgestellte Ansatz zur Datenassoziation ähnlich wie das ursprüngliche Verfahren [Hor09] Existenz- und Assoziationswahrscheinlichkeiten über eine gemeinsame Verteilung. In Kombination ergeben sich aus diesem Vorgehen einige Eigenschaften, die nachfolgend genauer betrachtet werden sollen.

Ein Nachteil ist mit der Annahme verbunden, dass pro Zeitschritt immer nur eine Entität beobachtet wird. Aus dieser Annahme resultiert, unter Verwendung des Verarbeitungsschemas mit Prädiktion und Aktualisierung in jedem Schritt, dass die Existenzwahrscheinlichkeit der Repräsentanten aller nicht beobachteten Entitäten in jedem Zeitschritt abnimmt. Dies gilt unabhängig davon, ob diese in der beobachteten Umgebung tatsächlich weiterhin vorhanden sind oder nicht. Für eine qualitative Betrachtung dieses Umstands und seiner Auswirkungen wurden einfache Simulationen durchgeführt. Dabei wurden die beiden in dieser Arbeit vorgeschlagenen Modelle einer vektorwertigen prioren Assoziationswahrscheinlichkeit in Ergänzung des bisherigen Ansatzes [Bau10] verwendet. In diesen Simulationen sanken die Existenzwahrscheinlichkeiten nicht beobachteter Repräsentanten bereits in einem Zeitschritt auf Werte im Bereich von nur 50%. Ein Umweltmodell wird sich unter diesen Voraussetzungen also sehr schnell unsicher über alle Entitäten, die aktuell nicht beobachtet werden. Um dieses Verhalten besser verstehen zu können, wurde der oben beschriebene Ansatz zur Datenassoziation auch quantitativ untersucht, wieder unter Verwendung der beiden

vorgeschlagenen Modelle für die priore Assoziation. Die Ergebnisse dieser Betrachtungen werden nachfolgend dargelegt.

Unabhängig vom genutzten Modell gilt für die gemeinsamen Existenz- und Assoziationswahrscheinlichkeiten $p(\underline{e}_k, d_k | \underline{y}_{1:k})$:

- Nach (5.34) nimmt die gemeinsame Wahrscheinlichkeit nur für Parameterkombinationen aus einer Assoziation $D_k^{r_i}$ (welche als $d_k = r_i$ definiert ist) und Existenzwahrscheinlichkeiten der Form $\underline{e}_k^{r_i}$ einen Wert ungleich 0 an. Dieser Wert wird nachfolgend mit p_i bezeichnet: $p_i := p(\underline{e}_k^{r_i}, D_k^{r_i} | \underline{y}_{1:k})$.

Um einfacher interpretierbare Aussagen ableiten zu können, wurde zunächst das einfache Modell der prioren Assoziation betrachtet. Dabei gilt:

- Im einfachen Modell hat die gemeinsame Verteilung $p(\underline{e}_k^{r_i}, D_k^{r_i} | \underline{y}_{1:k})$ unter der Annahme, dass der Repräsentant r_i existiert ($E_k^{r_i}$) und ihm die Beobachtung zugeordnet wird ($D_k^{r_i}$), für alle Belegungen der restlichen Existenzvariablen $e_k^{r_j}$ im Vektor $\underline{e}_k^{r_i}$, mit $r_j \neq r_i$, den gleichen Wert, nämlich p_i . Für eine feste Zuordnung $D_k^{r_i}$ tritt dieser Wert in der gemeinsamen Verteilung insgesamt $2^{|\mathcal{R}|-1}$ mal auf (für alle möglichen Kombinationen der restlichen Existenzvariablen).
- Die Normierungskonstante z_e für die Berechnung der gemeinsamen Verteilung nach (5.32) ergibt sich als Summe aller von Null verschiedenen Wahrscheinlichkeitswerte der gemeinsamen Verteilung. Für eine feste Zuordnung $D_k^{r_i}$ sind dies die $2^{|\mathcal{R}|-1}$ Werte p_i . Für alle möglichen Zuordnungen $d_k \in \{1, 2, \dots, |\mathcal{R}|\}$ ergibt sich z_e insgesamt dann als $z_e = 2^{|\mathcal{R}|-1} \cdot \sum_{i=1}^{|\mathcal{R}|} p_i$.
- Die Berechnung der Existenzwahrscheinlichkeit $p(E_k^{r_i} | \underline{y}_{1:k})$ eines einzelnen Repräsentanten erfolgt durch Marginalisierung anhand von (5.29) und (5.30). Hierbei ergeben sich als Summanden neben den $2^{|\mathcal{R}|-1}$ Werten p_i durch die Summation über d_k in (5.30) weitere Werte. Für alle Terme mit $d_k = r_j$, in denen neben $E_k^{r_i}$ auch $E_k^{r_j}$ in $\underline{e}_k^{r_i}$ gegeben ist, ergibt sich der Summand p_j . Der Wert p_j kann hierbei kombinatorisch über alle restlichen Existenzvariablen für Repräsentanten $\notin \{r_i, r_j\}$ insgesamt $2^{|\mathcal{R}|-2}$ mal auftreten.

Basierend auf diesen Überlegungen ergibt sich die normierte posteriore Existenzwahrscheinlichkeit $p(E_k^{r_i} | \underline{\hat{y}}_{1:k})$ eines Repräsentanten r_i somit als

$$\begin{aligned}
 p(E_k^{r_i} | \underline{\hat{y}}_{1:k}) &= \frac{2^{|\mathcal{R}|-1} \cdot p_i + \left(\sum_{j=1, j \neq i}^{|\mathcal{R}|} 2^{|\mathcal{R}|-2} \cdot p_j \right)}{2^{|\mathcal{R}|-1} \cdot \sum_{j=1}^{|\mathcal{R}|} p_j} \\
 &= \frac{2^{|\mathcal{R}|-2} \cdot \left(p_i + \sum_{j=1}^{|\mathcal{R}|} p_j \right)}{2^{|\mathcal{R}|-1} \cdot \sum_{j=1}^{|\mathcal{R}|} p_j} \\
 &= \frac{1}{2} \cdot \left(1 + \frac{p_i}{\sum_{j=1}^{|\mathcal{R}|} p_j} \right) .
 \end{aligned} \tag{5.43}$$

Die Wahrscheinlichkeiten p_i haben im einfachen Modell der prioren Assoziation (5.38) dabei die Form

$$p_i \sim p_k^{y_{r_i}} \cdot p_T \cdot p(E_k^{r_i} | \underline{\hat{y}}_{1:k-1}) , \tag{5.44}$$

in welcher $p_k^{y_{r_i}}$ die Wahrscheinlichkeit der prädizierten Beobachtung darstellt. Der Wert dieser Wahrscheinlichkeit hängt von der konkreten Zuordnung $d_k = r$ ab. Für Zuordnungen $d_k = r_i$, bei denen die Beobachtung $\underline{\hat{y}}_k$ in hohem Maß den Attributwerten des Repräsentanten r_i ähnelt, wird dieser Faktor für r_i groß im Gegensatz zu den Faktoren für die restlichen $r_j \neq r_i$. Dies spiegelt sich auch in p_i bzw. den verschiedenen p_j wider. Damit nimmt der Term $p_i / \sum_{j=1}^{|\mathcal{R}|} p_j$ einen Wert nahe 1 an, wodurch $p(E_k^{r_i} | \underline{\hat{y}}_{1:k}) \approx \frac{1}{2}(1 + 1)$ insgesamt ebenfalls Werte nahe 1 annimmt. Sind Beobachtung und Repräsentant allerdings hinreichend unähnlich ($d_k \neq r$), so verschwindet dieser Term nahezu, und $p(E_k^{r_i} | \underline{\hat{y}}_{1:k}) \approx \frac{1}{2}(1 + 0)$ ergibt sich als Wert nahe 0.5.

In Konsequenz ergeben sich die folgenden beiden Schlussfolgerungen aus obiger Betrachtung: bei Anwendung des einfachen Modells im Aktualisierungsschritt der Datenassoziation nimmt die Existenzwahrscheinlichkeit des aktuell beobachteten Repräsentanten einen Wert nahe 1 an, wobei seine priori Existenzwahrscheinlichkeit hierbei nur einen geringen Einfluss hat.

Weiterhin nehmen die Existenzwahrscheinlichkeiten aller im betrachteten Zeitschritt nicht beobachteten Repräsentanten Werte nahe 0.5 an.

Die gleiche Betrachtung wurde nun erneut unter Verwendung des komplexeren Modells der prioren Assoziation (5.40) durchgeführt. Auch hier ergibt sich für die posteriore Existenzwahrscheinlichkeit eines einzelnen Repräsentanten eine zu (5.43) ähnliche Struktur. Zu den Termen p_i kommen als Wert für die gemeinsame Existenz- und Assoziationswahrscheinlichkeit $p(\underline{e}_k, D_k^r | \underline{\hat{y}}_{1:k})$ allerdings noch weitere Terme hinzu, für alle $e_k^{r_j} = 1$ in \underline{e}_k (mit $j \neq i$). Diese Terme hängen von den entsprechenden prioren Existenzwahrscheinlichkeiten $p(E_k^{r_j} | \underline{\hat{y}}_{1:k-1})$ der Repräsentanten r_j ab und sind über die Wahrscheinlichkeit p_F einer Falschassoziation skaliert. Durch die Marginalisierung treten in den posterioren Existenzwahrscheinlichkeiten einzelner Repräsentanten weiterhin Terme auf, in denen die Wahrscheinlichkeiten $p_k^{y_{r_j}}$ prädizierter Beobachtungen anderer Repräsentanten enthalten sind. Die posterioren Existenzwahrscheinlichkeiten hängen somit formal von den prioren Existenzwahrscheinlichkeiten und Beobachtungswahrscheinlichkeiten aller r_j in \mathcal{R} ab.

Nimmt man vereinfachend gleiche priore Existenzwahrscheinlichkeit für alle Repräsentanten an, so ergibt sich mit dem komplexeren Modell der prioren Assoziation die normierte posteriore Existenzwahrscheinlichkeit $p(E_k^{r_i} | \underline{\hat{y}}_{1:k})$ als

$$\frac{1}{2} \left(1 + \frac{p_k^{y_{r_i}}}{\sum_{r_j \in \mathcal{R}} p_k^{y_{r_j}}} + \left(\left(1 + \frac{p_k^{y_{r_i}}}{\sum_{r_j \neq r_i} p_k^{y_{r_j}}} \right) \cdot \left(2 \cdot \frac{p_T}{p_F} + (|\mathcal{R}| - 1) \right) \right)^{-1} \right). \tag{5.45}$$

Dabei wird die ähnliche Struktur zu (5.43) sichtbar. Der Term $p_i / \sum_{j=1}^{|\mathcal{R}|} p_j$ ist für das komplexere Modell durch die normierte prädizierte Beobachtungswahrscheinlichkeit $p_k^{y_{r_i}} / \sum_{r_j \in \mathcal{R}} p_k^{y_{r_j}}$ ersetzt und um einen weiteren, positiven Summanden ergänzt. In Analogie zum einfachen Modell nimmt dieser

Term Werte nahe 1 an, falls die Beobachtung \hat{y}_k in hohem Maß den Attributwerten des Repräsentanten r_i ähnelt ($d_k = r_i$). Die posteriore Existenzwahrscheinlichkeit von r_i nimmt dann ebenfalls einen Wert nahe 1 an. Für unähnliche Beobachtungen mit $d_k \neq r_i$ verschwindet der Term nahezu, und der zweite Summand dominiert die Summe. Allerdings nimmt auch dieser im Falle unähnlicher Beobachtungen Werte nahe 0 an, in Abhängigkeit vom Verhältnis $\frac{p_T}{p_F}$ und der Anzahl an Repräsentanten $|\mathcal{R}|$ im Weltmodell. Je größer p_F im Verhältnis zu p_T ist, desto größer wird der zweite Summand – absolut sind die Werte allerdings immer noch relativ nahe an Null. Die Abweichung von Null führt allerdings dazu, dass sich beim komplexeren Modell der prioren Assoziation posteriore Existenzwahrscheinlichkeiten $> \frac{1}{2}$ ergeben. In einer Simulation mit 5 Repräsentanten und einem Verhältnis $p_F = 0.4 \cdot p_T$ ergeben sich z. B. Werte von 0.55 für Repräsentanten, die unähnlich zur Beobachtung sind, wenn die prioren Existenzwahrscheinlichkeiten als gleich angenommen werden.

Zusammenfassend ergeben sich somit unter Verwendung beider Modelle der prioren Assoziation ähnliche Ergebnisse für die durchgeführte Untersuchung, nämlich dass:

- die Existenzwahrscheinlichkeiten $p(E_k^{r_i} | \hat{y}_{1:k})$ von Repräsentanten nicht auf Werte > 0.5 abfallen,
- die Existenzwahrscheinlichkeit der in einem Zeitschritt beobachteten Entität Werte nahe 1 annimmt, ohne dass ihre priori Existenzwahrscheinlichkeit hierauf großen Einfluss hätte, und
- die Existenzwahrscheinlichkeiten der in einem Zeitschritt nicht beobachteten Entitäten sehr schnell auf Werte nahe 0.5 sinken.

Damit zeigt das bisherige Vorgehen zur Datenassoziation in der objektorientierten Umweltmodellierung zusammen mit den vorgeschlagenen Modellen einige Eigenheiten, die sich nicht notwendigerweise mit der intuitiv erwarteten zeitlichen Entwicklung der Existenzwahrscheinlichkeiten von Repräsentanten decken.

5.2.4 Alternativer Ansatz zur Assoziation

Als Konsequenz aus den oben genannten Nachteilen wird in dieser Arbeit ein alternativer Ansatz zur Berechnung der Existenzwahrscheinlichkeiten umgesetzt. Dieser Ansatz erweitert bzw. modifiziert das bisherige Vorgehen zur Datenassoziation [Bau10] in der objektorientierten Umweltmodellierung. Ziel dieser Erweiterung ist es dabei, vor allem die sich ergebende zeitliche Entwicklung der Existenzwahrscheinlichkeiten von Repräsentanten mehr der intuitiven Erwartung an diese anzupassen, wie sie z. B. in anderen Vorarbeiten zum objektorientierten Umweltmodell (z. B. [Hei10]) beschrieben wurde. Im Speziellen soll die Berechnung der aktuellen Existenzwahrscheinlichkeit eines Repräsentanten dabei signifikant von seiner prioren Existenzwahrscheinlichkeit abhängen. Weiterhin sollen die Existenzwahrscheinlichkeiten für nicht beobachtete Repräsentanten allmählich in Abhängigkeit des definierten Alterungsfaktors abfallen und auch Werte kleiner 0.5 annehmen können.

Dass der bisherige Ansatz zur Datenassoziation ein anderes Verhalten zeigt, liegt vor allem in der Annahme von nur einer beobachteten Entität pro Zeitschritt begründet, im Zusammenspiel mit dem Aufsetzen auf einem Ansatz [Hor09], in welchem für jedes Objekt eine Beobachtung pro Zeitschritt angenommen wird. Folglich beschreibt im Ansatz von [Hor09] die Tatsache, dass ein Objekt in einem Zeitschritt nicht beobachtet wird, ein Fehlen dieses Objekts. Eine derartige Beobachtung soll somit in einer deutlich verringerten Existenzwahrscheinlichkeit für dieses Objekt resultieren. Unter der Annahme von nur einer Beobachtung pro Zeit-, und vor allem, pro Verarbeitungsschritt besitzt die Nichtbeobachtung eines Objektes in einem Zeitschritt allerdings eine stark veränderte Semantik. Die Nichtbeobachtung beschreibt hierbei nur die Tatsache, dass das Objekt nicht im Fokus der aktuellen Beobachtung stand, jedoch kein grundsätzliches Fehlen des Objekts. Denn das Objekt kann jederzeit im Fokus einer der nächsten Beobachtungen stehen, ohne jemals gefehlt zu haben. Allein die Nichtbeobachtung eines Objektes über einen längeren Zeithorizont hinweg stellt einen Indikator für dessen Fehlen dar. Dieser grundsätzliche Unterschied zwischen den Annahmen für die objektorientierte Umweltmodellierung und dem Ansatz in [Hor09] soll

in dieser Arbeit nun durch Anpassung der bisherigen Datenassoziation Beachtung finden.

Dazu muss zunächst die gemeinsame Berechnung der Existenz- und Assoziationswahrscheinlichkeiten in Gleichung (5.32) betrachtet werden. Diese stellt die Grundlage für die Berechnung sowohl der Assoziationsverteilung über alle Repräsentanten als auch der Existenzwahrscheinlichkeit der einzelnen Repräsentanten dar. Über den Faktor der prädierten Messungen werden in dieser Gleichung die Existenzwahrscheinlichkeiten aller derjenigen Repräsentanten abgewichtet, die nicht hinreichend ähnlich zur betrachteten Beobachtung sind. Dieses Vorgehen ist angemessen zur Berechnung der Assoziationsverteilung. Unter der Annahme von nur einer Beobachtung pro Zeitschritt ist dieses Vorgehen aus dargelegten Gründen allerdings nicht zielführend für eine Berechnung der aktualisierten Existenzwahrscheinlichkeiten. Daher wird in dieser Arbeit ein alternatives Vorgehen zur Berechnung der Existenzwahrscheinlichkeiten gewählt, bei welchem eine separate Aktualisierung der Existenzwahrscheinlichkeiten in einem Schritt nach der Berechnung der Assoziationsverteilung erfolgt. Die Assoziationsverteilung wird weiterhin nach (5.31) auf Basis der gemeinsamen Existenz- und Assoziationswahrscheinlichkeit berechnet, allerdings ohne in (5.31) die aus der gemeinsamen Verteilung marginalisierten Existenzwahrscheinlichkeiten $p(E_k^r | \underline{\hat{y}}_{1:k})$ zu verwenden, da diese wie dargelegt nicht mit der getroffenen Annahme von nur einer Beobachtung vereinbar sind. Zur Berechnung der Assoziationswahrscheinlichkeit mittels (5.31) wird stattdessen vereinfachend angenommen, dass die marginalisierten Existenzwahrscheinlichkeiten hier keinen Einfluss haben, indem z. B. alle $p(E_k^r | \underline{\hat{y}}_{1:k})$ als gleich angenommen werden. Damit ergeben sich die Assoziationswahrscheinlichkeiten p_k^{dr} als proportional zur gemeinsamen Wahrscheinlichkeit von D_k^r und E_k^r , d. h.

$$p_k^{dr} \sim p(E_k^r, D_k^r | \underline{\hat{y}}_{1:k}) . \quad (5.46)$$

Diese gemeinsame Wahrscheinlichkeit kann wie bisher durch Marginalisierung mit E_k^r anhand von (5.29) berechnet werden, so dass insgesamt gilt:

$$p_k^{dr} \sim p(E_k^r, D_k^r | \underline{\hat{y}}_{1:k}) = \sum_{e_k^{r_1}, e_k^{r_2}, \dots, e_k^{r_{i-1}}, e_k^{r_{i+1}}, \dots, e_k^{r_{|\mathcal{R}|}}} p(\underline{e}_k^r, D_k^r | \underline{\hat{y}}_{1:k}) . \quad (5.47)$$

Die so erhaltenen Werte müssen anschließend noch über alle r in \mathcal{R} normiert werden (was beim Vorgehen nach [Hor09] unter Verwendung der marginalisierten Existenzwahrscheinlichkeiten erfolgt wäre). Bei Nutzung des einfachen Modells (5.38) der prioren Assoziation, welches nur Einflüsse des betroffenen Repräsentanten auf die gemeinsame Wahrscheinlichkeit $p(\underline{e}_k, d_k)$ berücksichtigt, ergibt sich die Assoziationswahrscheinlichkeit eines Repräsentanten zur Beobachtung $\underline{\hat{y}}_k$ dann als

$$p_k^{dr} = \frac{p_k^{y_{r_i}} \cdot p(E_k^{r_i} | \underline{\hat{y}}_{1:k-1})}{\sum_{r_j \in \mathcal{R}} p_k^{y_{r_j}} \cdot p(E_k^{r_j} | \underline{\hat{y}}_{1:k-1})} , \quad (5.48)$$

also als normiertes Produkt aus der Wahrscheinlichkeit der Messung eines Repräsentanten im prädierten Messmodell mit seiner prädierten Existenzwahrscheinlichkeit. Durch die Normierung ist der Wert unabhängig von der Trefferwahrscheinlichkeit p_T . Beim komplexeren Modell der prioren Assoziation gilt

$$p_k^{dr} = \frac{p_k^{y_{r_i}} \cdot \left(2 \cdot p_T \cdot p(E_k^{r_i} | \underline{\hat{y}}_{1:k-1}) + p_F \cdot \sum_{r_j \neq r_i} p(E_k^{r_j} | \underline{\hat{y}}_{1:k-1}) \right)}{\sum_{r_j \in \mathcal{R}} \left(p_k^{y_{r_j}} \cdot \left(2 \cdot p_T \cdot p(E_k^{r_j} | \underline{\hat{y}}_{1:k-1}) + p_F \cdot \sum_{r \neq r_j} p(E_k^r | \underline{\hat{y}}_{1:k-1}) \right) \right)} , \quad (5.49)$$

und es wird ersichtlich, dass einerseits die Wahrscheinlichkeiten für Treffer p_T sowie für Falschalarne p_F eine Rolle spielen (bzw. ihr Verhältnis) und

andererseits auch die Existenzwahrscheinlichkeiten anderer Repräsentanten bei der Assoziation einer Beobachtung zu r_i berücksichtigt werden.

Die Aktualisierung der Existenzwahrscheinlichkeiten erfolgt schließlich auf Basis der berechneten Assoziationswahrscheinlichkeit p_k^{dr} analog zur Aktualisierung der Attributwahrscheinlichkeiten in (5.28). Hierbei wird für alle Repräsentanten r , die einen Anteil $p_k^{dr} > 0$ an der Beobachtung haben, eine gewichtete Summe gebildet, in welche die beiden Fälle einfließen, dass die Entität entweder beobachtet wurde oder nicht, jeweils gewichtet über p_k^{dr} bzw. $1 - p_k^{dr}$. Für den Fall einer Nichtbeobachtung wird dabei die prädiizierte Existenzwahrscheinlichkeit genutzt. Für den Fall, dass die Entität tatsächlich beobachtet wurde, wird eine gefilterte Existenzwahrscheinlichkeit $p(E_k^r | D_k^r)$ angenommen, die per Definition auf 1 gesetzt wird. Dabei wird angenommen, dass eine Entität, die detektiert wurde, auch mit Sicherheit existiert - und daher die Existenzwahrscheinlichkeit ihres Repräsentanten auf 1 gesetzt werden sollte unter der Voraussetzung, dass die Entität durch eine Beobachtung erfasst wurde. Dies entspricht dem Vorgehen, die Messunsicherheit in einem reinen Detektionsmodell, welchem ein Assoziationsmodell vorgeschaltet ist, auf Null zu setzen. Mit diesem Vorgehen ergibt sich dann die aktualisierte Existenzwahrscheinlichkeit für einen Repräsentanten r als

$$\begin{aligned}
 p(E_k^r | \hat{y}_{1:k}) &= p_k^{dr} \cdot \underbrace{p(E_k^r | D_k^r)}_{\substack{\text{Beobachtete} \\ \text{Existenz}}} + (1 - p_k^{dr}) \cdot \underbrace{p(E_k^r | \hat{y}_{1:k-1})}_{\text{Präd. Existenz}} \\
 &= p_k^{dr} + (1 - p_k^{dr}) \cdot p(E_k^r | \hat{y}_{1:k-1}) . \quad (5.50)
 \end{aligned}$$

5.2.5 Demonstration der Datenassoziation

Um die grundsätzliche Funktionsfähigkeit des wie vorgestellt erweiterten Ansatzes zur Datenassoziation mit den vorgeschlagenen Modellen der priorren Assoziation zu demonstrieren, wurde eine Simulation durchgeführt. Zu diesem Zweck wurde ein abstraktes Szenario angenommen, in welchem Entitäten vereinfachend über nur zwei Attribute beschrieben werden, nämlich

ein diskretes und ein stetiges Attribut. Dabei wurde für das diskrete Attribut ein ordinal skaliertes Merkmal gewählt und für das stetige ein verhältnisskaliertes Merkmal. Als ordinales Attribut a_k^1 wird hier beispielhaft die Farbe einer Entität verwendet, beschrieben über symbolische Werte f_i (wie rot, orange, gelb, etc.), die anhand ihrer korrespondierenden Frequenzen im Farbspektrum geordnet werden können. Als stetiges Attribut a_k^2 wird beispielhaft die Länge der Entität verwendet.

Betrachtung der Informationsalterung

Zur Demonstration der Datenassoziation wurden zunächst fünf Entitäten simuliert, welche durch die Repräsentanten r_1, r_2, r_3, r_4 und r_5 im Weltmodell repräsentiert werden. Die Entitäten werden dabei zu verschiedenen Zeitpunkten t_k beobachtet. Die durch r_2 dargestellte Entität wird beispielsweise im Zeitschritt t_k mit $k = 2$ zum ersten Mal beobachtet, und dann erneut im Zeitschritt $k = 5$ ¹. Im Zeitschritt $k = 2$ wird dementsprechend ein neuer Repräsentant initialisiert, welcher dann über die Zeitschritte $k = 3$ bis $k = 5$ durch Alterung zeitlich fortgeschrieben wird. Dies ist in Abbildung 5.1 dargestellt. Die Initialisierung (5.1a) erfolgt dabei auf Basis der Beobachtung \hat{y}_2 . In den folgenden zwei Zeitschritten (5.1b, 5.1c) ohne erneute Beobachtung altern die Attribute, wobei hier als Alterungsfaktor für die Existenzwahrscheinlichkeit ein Wert von $\beta_c = 0.95$ angenommen wurde. Die zeitliche Fortschreibung der deskriptiven Attribute erfolgt für das ordinale Farbattribut unter Verwendung des Transitionsmodells (5.17) mit einem Alterungsfaktor von $\beta_{a^1} = 0.975$. Das kontinuierliche Längenattribut wird anhand von (5.13) und (5.14) fortgeschrieben, wobei ein mittelwertfreies Systemrauschen v_k mit $\sigma_v = 0.02$ m angenommen wurde. In Abbildung 5.1c sind die prioren Verteilungen der Attribute des Repräsentanten r_2 für den Zeitschritt $k = 5$ dargestellt, und das Absinken der Existenzwahrscheinlichkeit $p(E_5^{r_2})$ vom Initialwert 1 auf einen Wert von 0.86 wird deutlich. Dies entspricht


¹ Konkrete Zeitschritte t_k werden in dieser Arbeit verkürzend durch die Angabe des Werts für k spezifiziert, z. B. $k = 5$ – dies ist gleichbedeutend mit der Notation t_5 .

dem durch den alternativen Ansatz der Assoziationsberechnung intendierten Verhalten einer langsamen, stetigen Abnahme der Existenzwahrscheinlichkeit, wenn eine Entität über mehrere Zeitschritte hinweg nicht beobachtet wird. Weiterhin ist in 5.1c auch die Zunahme in der Unsicherheit des Längenattributs auf einen Wert von $\sigma_5^{a^2} = 0.02 \text{ m}$ zu erkennen.


Betrachtung der Datenassoziation

Im Zeitschritt $k = 5$ erfolgt als Resultat der Datenassoziation eine Aktualisierung des Repräsentanten r_2 durch die Beobachtung \hat{y}_5 . In der Simulation wird dabei das einfache Modell (5.38) der prioren Assoziation verwendet. Grundlage für die Berechnung der Datenassoziationsverteilung $p_k^{d^r}$ sind nach (5.32) und (5.48) die prioren Existenzwahrscheinlichkeiten $p(E_5^{r_i})$ sowie die Attributverteilungen $\underline{a}_5^{r_i}$ aller Repräsentanten r_i in \mathcal{R} bezüglich der Berechnung der prädizierten Messverteilungen. In Abbildung 5.2 sind diese Ausgangswerte für die Repräsentanten r_1 (5.2a), r_3 (5.2b) und r_4 (5.2c) dargestellt. Weiterhin zeigt die Abbildung in 5.2d zum Vergleich die in der Beobachtung \hat{y}_5 enthaltenen Messungen für das Farb-Attribut a_5^1 sowie für das Längen-Attribut a_5^2 . Die Messwerte $\hat{y}_5^1 = f_4$ und $\hat{y}_5^2 = 0.18 \text{ m}$ sind dabei als Verteilungen dargestellt, unter Verwendung der in der Simulation genutzten Messabweichungen, nämlich einer Sicherheit von $\sigma_d = 95\%$ bei der Messung von Farbmerkmalen sowie einer Messunsicherheit von $\sigma_\gamma = 0.01 \text{ m}$ für die Längenmessung.


Mit den dargestellten Werten ergibt sich für die Datenassoziation im Zeitschritt $k = 5$ eine Zuordnung d_5 mit $p(D_5^{r_2}) \approx 99.6\%$. Unter Verwendung dieser Zuordnung d_5 erfolgt dann eine Aktualisierung des Repräsentanten r_2 , deren Ergebnis in Abbildung 5.1d dargestellt ist. Dabei ist zu erkennen, dass die Existenzwahrscheinlichkeit wie gefordert bei Beobachtung der repräsentierten Entität einen Wert nahe 1 annimmt. Weiterhin werden die Attributverteilungen gemäß den aktuellen Messwerten für die repräsentierten Merkmale angepasst.




(a) Initiale Attributverteilungen für Repräsentant r_2 in Zeitschritt $k = 2$



(b) Attributverteilungen für Repräsentant r_2 in Zeitschritt $k = 3$



(c) Priore Attributverteilungen für Repräsentant r_2 in Zeitschritt $k = 5$



(d) Posteriore Attributverteilungen für Repräsentant r_2 in Zeitschritt $k = 5$

Abbildung 5.1: Szenario für die Demonstration der Datenassoziation. Dargestellt ist die Entwicklung von Repräsentant r_2 über 4 Zeitschritte mit Initialisierung in $k = 2$ und Alterung über die Zeitschritte $k = 3, 4, 5$. In Zeitschritt $k = 5$ wird r_2 weiterhin durch eine Beobachtung aktualisiert (Ergebnisse eines Aktualisierungsschrittes in grün dargestellt).





(a) Prior Attributeverteilungen für Repräsentant r_1 in Zeitschritt $k = 5$ (b) Prior Attributeverteilungen für Repräsentant r_3 in Zeitschritt $k = 5$ (c) Prior Attributeverteilungen für Repräsentant r_4 in Zeitschritt $k = 5$ (d) Messwerte der Beobachtung y_5 in Zeitschritt $k = 5$ für die Attribute Farbe und Länge, dargestellt als Verteilungen mit Messunsicherheiten.

Abbildung 5.2: Demonstration der Datenassoziation. Dargestellt sind prior Attributeverteilungen für die Repräsentanten r_1 , r_3 und r_4 , welchen in Zeitschritt $k = 5$ zusammen mit dem Repräsentanten r_2 die dargestellte Beobachtung zuzuordnen ist.

Diskussion

Das für den Zeitschritt $k = 5$ dargestellte Verhalten kann dabei als exemplarisch für eine Demonstration der in der Arbeit erweiterten Datenassoziation und Informationsverarbeitung in der objektorientierten Umweltmodellierung angesehen werden. Es ergibt sich in ähnlicher Weise auch in den weiteren Zeitschritten, für welche die Simulation durchgeführt wurde. Auch bei Verwendung des komplexeren Modells der prioren Assoziation ergeben sich in der Simulation grundsätzlich ähnliche Ergebnisse, die das gewünschte Verhalten der erweiterten Datenassoziation demonstrieren.

Eine weitere Feststellung lässt sich für den Fall der vereinfachten Modellierung von Entitäten über nur zwei Attribute treffen. Sie betrifft die zeitliche Fortschreibung deskriptiver Attribute im Falle von geringen Werten für Alterungsfaktoren bzw. großer Unsicherheiten in der Prädiktion in Kombination mit Repräsentanten, die über viele Zeitschritte nicht beobachtet werden. In dieser Situation kann die mit der Zeit auftretende Verbreiterung der Attributverteilungen dazu führen, dass sich ähnliche Repräsentanten nicht mehr ausreichend unterscheiden lassen. In diesem Fall ist dann auch die Datenassoziation nicht mehr in der Lage, zwischen den Repräsentanten zu unterscheiden. Werden Repräsentanten durch eine größere Anzahl von Attributen charakterisiert, ist dieser Fall allerdings weniger wahrscheinlich.

5.3 Informationsverwaltung

Das objektorientierte Umweltmodell stellt Informationen, welche über die relevante Umgebung erworben wurden, weiteren Komponenten eines kognitiven Systems zur Nutzung bereit. Um diese Aufgabe gewinnbringend und mit entsprechender Informationsqualität ausführen zu können, müssen im Umweltmodell kontinuierlich Operationen zur Verwaltung der erworbenen Umgebungsinformationen durchgeführt werden. In dieser Arbeit werden alle Operationen, welche sich mit der Verwaltung der im Weltmodell gespeicherten Repräsentanten und ihrer Beziehungen untereinander beschäftigen, zur Informationsverwaltung des Umweltmodells gezählt. Dies

beinhaltet auch die probabilistische Informationsverarbeitung [Ghe08]. Verwaltungsoperationen des Weltmodells betreffen unter anderem die Erzeugung neuer Repräsentanten für bisher unbeobachtete Entitäten, das Löschen bzw. Entfernen von nicht mehr als relevant betrachteten Repräsentanten sowie die Verwaltung der Relationen zwischen den Repräsentanten. Weiterhin werden Qualitätsprüfungen für Repräsentanten und Relationen im Rahmen der Informationsverwaltung durchgeführt, welche die Güte der repräsentierten Umgebungsinformationen sicherstellen sollen, indem beispielsweise Anforderungen an die formale Repräsentation, Konsistenz und Aktualität der Umgebungsinformationen umgesetzt werden. Auch die probabilistische Zuordnung von Repräsentanten zu Konzepten gehört zur Informationsverwaltung. Nachfolgend wird in diesem Abschnitt das Vorgehen der objektorientierten Umweltmodellierung zur Informationsverwaltung vorgestellt. Dieses Vorgehen wurde dabei jeweils in den nachfolgend genannten Vorarbeiten festgelegt. Diese Arbeit ergänzt dieses festgelegte Vorgehen an einigen Stellen nun um weitere Aspekte, z. B. in Bezug auf die Verwaltung von Entitätshypothesen. Weiterhin setzt sich diese Arbeit konzeptuell mit der Verwaltung von Relationen auseinander.

5.3.1 Verwaltung von Repräsentanten

In der objektorientierten Umweltmodellierung wird der Zustand der beobachteten Umgebung durch das Weltmodell mit seinen Repräsentanten und Relationen beschrieben. Deren Existenzwahrscheinlichkeit gibt dabei an, für wie wahrscheinlich das Vorhandensein der entsprechenden Entitäten und Beziehungen in der realen Umgebung gehalten wird. Repräsentanten können somit als Hypothesen über die Existenz sowie die Merkmalsausprägungen beobachteter Entitäten betrachtet werden.

In einer sich zeitlich ändernden Umgebung müssen diese Hypothesen dynamisch durch einen entsprechenden Prozess verwaltet werden. Die probabilistische Informationsverarbeitung sorgt dabei für die Aktualisierung der bestehenden Hypothesen. Weiterhin muss nun allerdings auch die Anzahl der Hypothesen dynamisch an die aktuellen Verhältnisse angepasst werden.

Treten z. B. in der betrachteten Umgebung bisher unbeobachtete Entitäten auf, so müssen für diese Entitäten und ihre Merkmalsausprägungen neue Hypothesen erzeugt werden. Gleichzeitig kann es passieren, dass ab einem gewissen Zeitpunkt bestimmte bestehende Hypothesen aufgrund von Umgebungsinformationen nicht mehr als gültig betrachtet werden können. In diesem Fall müssen die entsprechenden Repräsentanten aus dem Weltmodell entfernt werden. Diese Betrachtungen gelten analog auch für die Relationen zwischen Repräsentanten.

Das Bestätigen und Verwerfen von Hypothesen über die Existenz von Entitäten und Beziehungen in der realen Welt erfolgt im Weltmodell auf Basis des Existenzattributs. Sinkt z. B. der Wert des Existenzattributs eines im Weltmodell enthaltenen Repräsentanten bzw. einer Relation unter einen definierten Minimalwert ab, so wird das entsprechende Objekt aus dem Weltmodell entfernt. Die Aufnahme neuer Repräsentanten ins Weltmodell ist hingegen ein zweistufiger Prozess, welcher im nachfolgenden Abschnitt detailliert beschrieben wird. Dabei wird zunächst zur Repräsentation einer bisher unbeobachteten Entität eine neue Entitätshypothese erstellt, welche die Merkmalsausprägungen der betrachteten Entität beschreibt sowie eine Existenzwahrscheinlichkeit zugeordnet bekommt. Übersteigt diese Existenzwahrscheinlichkeit eine definierte Schwelle, so wird die Hypothese als bestätigt angesehen und als neuer Repräsentant ins Weltmodell aufgenommen. Über die Existenz neuer Relationen kann basierend auf den im Weltmodell enthaltenen Repräsentanten entschieden werden.

Erzeugung neuer Repräsentanten

Um eine sich zeitlich ändernde Umgebung modellieren zu können, muss das Weltmodell unter anderem in der Lage sein, mit einer dynamischen Anzahl an repräsentierten Entitäten umzugehen. Ein wichtiger Aspekt, welcher eng mit dem Problem der Datenassoziation verwoben ist, ist dabei die Erzeugung zusätzlicher Repräsentanten im Fall des Auftretens neuer, bisher unbeobachteter Entitäten. Dieser Fall muss bereits in der Datenassoziation berücksichtigt werden, indem bei der Zuordnung von Beobachtungen zu gegebenen

Repräsentanten auch die zusätzliche Möglichkeit vorgesehen ist, eine Beobachtung keinem der bisherigen Repräsentanten im Weltmodell zuzuordnen, sondern als neues Objekt auszuweisen. Die Datenassoziation der objektorientierten Umweltmodellierung basiert auf dem von Horridge und Maskell [Hor09] beschriebenen Ansatz. Dieser wurde für das Anwendungsgebiet der Verfolgung von Objektpositionen entwickelt und führt zusätzlich zu den bekannten Objekten ein explizites Suchobjekt ein, stellvertretend für bisher unbeobachtete Objekte. Das Suchobjekt wird bei der Berechnung der Datenassoziation wie ein bekanntes Objekt behandelt und kann als Hypothese über das Auftreten eines neuen Objekts verstanden werden.

In dieser Arbeit wird ein Ansatz zur Erzeugung neuer Repräsentanten vorgeschlagen, welcher gegenüber den Vorarbeiten zum objektorientierten Umweltmodell [Ghe10a, Bau10] leichte Anpassungen vornimmt. Diese Anpassungen erfolgen in Analogie zur in dieser Arbeit vorgeschlagenen Erweiterung der Datenassoziation. Der in dieser Arbeit vorgeschlagene Ansatz folgt dabei dem Vorgehen in [Hor09] und passt dieses für die objektorientierte Umweltmodellierung an. Wie oben erwähnt, wird dazu ein zweistufiger Prozess genutzt, in welchem zunächst Hypothesen für unbekannte Entitäten erzeugt werden und diese bei Bestätigung dann als Repräsentanten ins Weltmodell aufgenommen werden. Zu diesem Zweck hält die Datenassoziation in jedem Zeitschritt zusätzlich eine Hypothese für neue Beobachtungen vor, analog zum Suchobjekt in [Hor09]. Diese Entitätshypothese dient dabei als Stellvertreter-Repräsentant für bisher unbeobachtete Entitäten und besitzt Attribute für dieselben Qualitäten wie die Repräsentanten im Weltmodell. Im Falle des Auftretens einer unbekannten Entität ordnet die Datenassoziation nun die entsprechende Beobachtung der Entitätshypothese zu (gegebenenfalls auch nur anteilig) und die Attribute der Entitätshypothese werden entsprechend der beobachteten Messwerte aktualisiert. Dies betrifft auch die Existenzwahrscheinlichkeit. Überschreitet diese nun nach Aktualisierung einen definierten Schwellwert, so wird die aktuelle Entitätshypothese samt all ihrer Attribute als vollwertiger Repräsentant ins Weltmodell aufgenommen. Für den nachfolgenden Zeitschritt wird dann eine neue Entitätshypothese angelegt. Ist die Existenzwahrscheinlichkeit dagegen zu

gering, so wird die aktuelle Entitätshypothese im nachfolgenden Zeitschritt probabilistisch weiterverarbeitet.

In den Vorarbeiten zum objektorientierten Umweltmodell [Ghe10a, Bau10] wird ein leicht von diesem Vorgehen abweichender Ansatz zur Erzeugung neuer Repräsentanten beschrieben. Hier wird nur für den Fall eines negativen Ergebnisses der Datenassoziation, d. h. einer Rückweisung aller bisher im Weltmodell enthaltenen Repräsentanten, eine neue Entitätshypothese erzeugt und mit initialen Attributwerten belegt. In einem der nachfolgenden Zeitschritte muss diese Hypothese dann durch eine erneute Beobachtung bestätigt werden und ihre Attribute müssen durch die Messwerte der Beobachtung aktualisiert werden, um als Repräsentant ins Weltmodell aufgenommen zu werden. Der in dieser Arbeit vorgeschlagene, analog zu [Hor09] angelegte Ansatz, ständig eine Entitätshypothese vorzuhalten, bietet gegenüber dem bisherigen Vorgehen [Ghe10a, Bau10] den Vorteil, dass beim Auftreten einer bisher unbeobachteten Entität die Entitätshypothese direkt mit den beobachteten Merkmalsausprägungen aktualisiert und ins Weltmodell aufgenommen werden kann.

Nachfolgend werden die Details der probabilistischen Verarbeitung der Entitätshypothese in dieser Arbeit beschrieben. Die Entitätshypothese wird hierbei als r_0 bezeichnet und durch den Index 0 symbolisiert. Zunächst werden beim Anlegen einer neuen Entitätshypothese die Attributverteilungen mit vordefinierten Werten initialisiert. Die Werte repräsentieren das Vorwissen über mögliche Ausprägungen eines jeden Merkmals innerhalb der betrachteten Domäne und sind in Form von A-priori-Verteilungen gegeben. Details für eine mögliche Bestimmung solcher A-priori-Verteilungen werden in Abschnitt 6.4.2 beschrieben. Auch für die Existenzwahrscheinlichkeit wird ein Initialwert festgelegt, welcher die Unsicherheit über das tatsächliche Existieren der entsprechenden Entität widerspiegeln soll. Anschließend wird die Entitätshypothese in jedem Zeitschritt probabilistisch verarbeitet, also zeitlich fortgeschrieben, anteilig mit der Beobachtung des Zeitschritts assoziiert und entsprechend aktualisiert.

Im Ansatz von Horridge und Maskell [Hor09] weicht die zeitliche Fortschreibung der Existenzwahrscheinlichkeit des Suchobjekts leicht vom für Repräsentanten in Vorarbeiten etablierten Vorgehen ab. Hier wird mit einer bestimmten Wahrscheinlichkeit auch die Möglichkeit berücksichtigt, dass das Suchobjekt im aktuellen Zeitschritt nicht ein bereits in einem der vorhergehenden Zeitschritte entdecktes Objekt beschreibt, sondern ein im aktuellen Zeitschritt komplett neu entdecktes Objekt. Das Auftreten dieses Falles wird dabei mit der Wahrscheinlichkeit $p(\bar{E}_{k-1}^{r_0})$ gewichtet, welche das Nicht-Existieren des Suchobjektes im direkt vorhergehenden Zeitschritt t_{k-1} beschreibt. Im entgegengesetzten Fall mit der Wahrscheinlichkeit $p(E_{k-1}^{r_0})$, dass das Suchobjekt bereits existierte, wird diese Wahrscheinlichkeit wie bisher mit einem vordefinierten Faktor gemindert. Beide Fälle werden in [Hor09] zur zeitlichen Fortschreibung der Existenzwahrscheinlichkeit des Suchobjekts additiv kombiniert. Für die zeitliche Fortschreibung der Entitätshypothese r_0 wird in dieser Arbeit das beschriebene Vorgehen in angepasster Form übernommen. Hierbei wird die Konvexkombination

$$p(E_k^{r_0}) := \underbrace{p(\bar{E}_{k-1}^{r_0})}_{\text{Gewichtung}} \cdot p(E_0^{r_0}) + \underbrace{p(E_{k-1}^{r_0})}_{\text{Gewichtung}} \cdot p(E_{k-1}^{r_0}) \quad (5.51)$$

gebildet, in welcher der Term $p(E_{k-1}^{r_0})$ in zwei unterschiedlichen Rollen auftritt. Dabei ist die Wahrscheinlichkeit einer im aktuellen Zeitschritt neu beobachteten Entität durch die initiale Existenzwahrscheinlichkeit $p(E_0^{r_0})$ gegeben und die Wahrscheinlichkeit, eine in einem vorherigen Zeitschritt neu entdeckte Entität weiter zu beobachten, durch die bisherige Existenzwahrscheinlichkeit $p(E_{k-1}^{r_0})$. Die Gewichtung bleibt unverändert gegenüber dem Vorgehen in [Hor09]. Insgesamt ergeben sich bei diesem Ansatz Werte zwischen $p(E_0^{r_0})$ und $p(E_{k-1}^{r_0})$ sowie im Speziellen Werte $\approx p(E_0^{r_0})$ für $p(E_{k-1}^{r_0}) < p(E_0^{r_0})$.

Demselben Prinzip folgend, wird analog zu [Hor09] auch bei der Prädiktion der deskriptiven Attribute $\underline{a}_k^{r_0}$ der Entitätshypothese r_0 die Möglichkeit berücksichtigt, dass aktuell eine komplett neue Entität beobachtet wurde. Dabei werden die aktuellen Attribute der Entitätshypothese mit initialen

Attributwerten kombiniert, wobei letztere wieder mit der Wahrscheinlichkeit $p(\bar{E}_{k-1}^{r_0})$ der bisherigen Nicht-Existenz der Entitätshypothese gewichtet werden, und erstere mit $p(E_{k-1}^{r_0})$. An dieser Stelle sei angemerkt, dass für stetige Attribute durch diese Kombination eine Zunahme der Komponenten in ihrer Verteilung auftreten kann, so dass hier die Durchführung einer Komponentenreduktion sinnvoll sein kann.

Die Assoziation der Entitätshypothese zu einer Beobachtung erfolgt dann nach dem in Abschnitt 5.2.2 beschriebenen Schema. Auch die aktualisierte Existenzwahrscheinlichkeit kann anschließend anhand der bestimmten Assoziationsverteilung wie in 5.2.4 beschrieben berechnet werden. Dieser aktualisierte Wert bildet nun die Grundlage für die Entscheidung über die Aufwertung der Entitätshypothese zu einem vollwertigen Repräsentanten des Weltmodells [Hei10]. Dies ist der Fall, wenn die aktualisierte Existenzwahrscheinlichkeit $p(E_k^{r_0})$ den Schwellwert γ_i überschreitet.

Für den Fall einer Aufwertung der Entitätshypothese gehen nach [Hor09] keine Anteile aus einer möglichen Fehldetektion ein. Umgesetzt für die Datenassoziation im objektorientierten Umweltmodell bedeutet dies, dass im Falle einer Aufwertung bei Aktualisierung der deskriptiven Attribute der Entitätshypothese in (5.23) kein direkter Anteil der prioren Verteilung eingeht, sondern nur die Ergebnisse des Filterschritts berücksichtigt werden, äquivalent zu $p_k^{d^r} = 1$. Wird dagegen die Entitätshypothese nicht aufgewertet, erfolgt die Aktualisierung der deskriptiven Attribute wie in Abschnitt 5.2.1 beschrieben. Als Ersatz für eine aufgewertete Entitätshypothese wird anschließend eine neue Hypothese erzeugt und mit den für die Attribute definierten Initialwerten belegt.

Weiterhin sei angemerkt, dass durch die Einführung der Entitätshypothese allgemein sowie im Falle einer Aufnahme eines neuen Repräsentanten die Erweiterung einiger Vektoren der Datenassoziation, z. B. des Vektors der Existenzwahrscheinlichkeiten \underline{e}_k , sowie der Wertebereich der Assoziationsvariablen d_k notwendig wird.

5.3.2 Entfernen von Repräsentanten

Die Informationsverwaltung sieht neben der Erzeugung neuer Repräsentanten auch die Möglichkeit vor, nicht mehr relevante Repräsentanten zu löschen, d. h. aus dem Weltmodell zu entfernen. Die Motivation hierfür ist eine Schlankhaltung des Weltmodells [Hei10] in dem Sinne, dass Repräsentanten entfernt werden, wenn sie als veraltet gelten. Die Alterung eines Repräsentanten ist aufgrund der probabilistischen Informationsverarbeitung gleichbedeutend mit einer Zunahme der Unsicherheit in Existenzwahrscheinlichkeit sowie in deskriptiven Attributen des Repräsentanten. Ein schlankes Weltmodell bietet den Vorteil, dass Verarbeitungs- und Verwaltungsoperationen mit weniger Aufwand durchgeführt werden können. Dies betrifft sowohl die Informationsverwaltung im objektorientierten Umweltmodell mitsamt der probabilistischen Informationsverarbeitung als auch von anderen Komponenten des kognitiven Systems ausgehende Informationsanfragen an das Umweltmodell.

Die Entscheidung darüber, ob ein Repräsentant aus dem Weltmodell zu löschen ist, wird auf Basis seiner aktuellen Existenzwahrscheinlichkeit getroffen. Ein Repräsentant r wird aus dem Weltmodell gelöscht, wenn seine aktualisierte Existenzwahrscheinlichkeit einen vorgegebenen Schwellwert unterschreitet: $p(E_k^r) < \gamma_e$ [Hei10, Ghe10b, Bau10]. Dies gilt ebenso für Relationen, deren Verwaltung genauer im Abschnitt 5.3.4 beschrieben wird.

Abbildung 5.3 zeigt den Zusammenhang zwischen γ_e und dem Schwellwert γ_i für die Erzeugung neuer Repräsentanten in der objektorientierten Umweltmodellierung. Die gezeigte Kurve beschreibt dabei eine Hysterese. Die Intension des gewählten Zusammenhanges ist es, dass Repräsentanten nach ihrer Erzeugung nicht direkt wieder gelöscht werden [Hei10], sondern sich ihnen die Möglichkeit bietet, durch eine erneute Beobachtung der repräsentierten Entität innerhalb eines gewissen Zeitrahmens bestätigt zu werden. Die Länge dieses Zeitrahmens hängt dabei von den genutzten Alterungsfaktoren β ab.

Weiterhin kann zusätzlich der Schwellwert γ_r genutzt werden, welcher als ein Auslöser dient, um eine gezielte Wiederbestätigung der Existenz der repräsentierten Entität durch eine Sensorbeobachtung zu veranlassen [Bel09, Hei10]. Dies kann z. B. im Rahmen der Qualitätsprüfungen erfolgen. Eine aktive Wiederbestätigung setzt allerdings eine Anfrageschnittstelle zur Sensorsteuerung des kognitiven Systems voraus.




Abbildung 5.3: Schwellwerte γ_i für das Erzeugen und γ_e für das Löschen von Repräsentanten als Hysterese, welche eine ausreichend große Zeitspanne zwischen beiden Ereignissen sicherstellen soll, sowie γ_r für das Auslösen einer Wiederbestätigungsanforderung (nach [Hei10, Ghe10a]).

Archivierung erworbener Informationen

Im Zusammenhang mit dem Entfernen von Repräsentanten aus dem Weltmodell stellt sich eine grundsätzliche Frage. Diese Frage ist, ob einmal erworbene Umgebungsinformationen wieder verworfen, d. h. endgültig gelöscht werden sollten, falls sie aktuell nicht mehr relevant erscheinen, oder ob diese besser für eine mögliche spätere Verwendung nur ausgelagert werden sollten, z. B. durch Archivierung.

Dass ein endgültiges Löschen nicht immer vorteilhaft ist, wird in Vorarbeiten zum objektorientierten Umweltmodell anhand des Beispiels motiviert, dass aktuell nicht mehr beobachtbare Repräsentanten nach gewisser Zeit wieder relevant werden können [Bel09]. Als ein Beispiel aus der Haushaltsdomäne wird dabei in [Bel09] konkret Geschirr genannt, welches sich für

einen Zeitraum in einer Spülmaschine befindet. Während dieser Zeit könnten die Repräsentanten für diese Geschirrtteile nun aus dem Weltmodell gelöscht werden. Das Beispiel merkt weiterhin an, dass das Geschirr nach Ende des Spülvorgangs wieder aus der Spülmaschine ausgeräumt werden muss. Zu diesem Zweck kann das Wissen, dass sich die Geschirrtteile in der Spülmaschine befinden, und welche Eigenschaften diese Geschirrtteile besitzen, wieder hilfreich sein.

Der Schlankhaltung des Weltmodells durch Löschen von veralteten Repräsentanten steht weiterhin der Erfahrungswert gegenüber, welcher ein Repräsentant darstellt. Dieser ist in Form der über die relevante Umwelt erworbenen Informationen im Repräsentanten gegeben, welche in den Verteilungen seiner perceptiven und deduktiven Attribute vorliegen. Für zustandsbezogene, zeitabhängige Attribute kann dies beispielsweise die Position der dargestellten Entität zum entsprechenden Zeitpunkt sein, oder auch ihr Alter (z. B. für Lebensmittel) oder aktuelle Verwendbarkeit. Auch statische Attribute können einen Erfahrungswert darstellen, wie z. B. die tatsächlichen Abmessungen oder konkrete Farbe eines beobachteten Gegenstandes, gegenüber den im entsprechenden Konzept des Hintergrundwissens modellierten allgemeineren Attributwerten. Unter Betrachtung dieses Erfahrungswerts bietet sich eine Archivierung bestimmter Repräsentanten als Alternative zu ihrer endgültigen Löschung aus dem Weltmodell an. Als wie wertvoll spezifische Informationen über beobachtete Entitäten eines bestimmten Typs betrachtet werden, hängt von den konkreten Aufgabenstellungen eines kognitiven Systems ab und kann bereits zur Modellierungszeit des Systems definiert werden. Zu diesem Zweck lässt sich in entsprechenden Konzepten des Hintergrundwissens beispielsweise ein Individualitätsfaktor festlegen, welcher bestimmt, als wie wertvoll die durch Beobachtung einer Entität des entsprechenden Typs erworbenen Informationen angesehen werden. Als je wertvoller diese Informationen gelten, desto eher sollte ein entsprechender Repräsentant nicht endgültig aus dem Weltmodell gelöscht, sondern archiviert werden.

Im objektorientierten Umweltmodell können die Zustandshistorie sowie zusätzliche Mechanismen für eine Archivierung relevanter Repräsentanten genutzt werden, welche in Abschnitt 5.4 genauer beschrieben werden.

5.3.3 Qualitätsprüfungen

Im Weltmodell wird der beobachtete Umgebungszustand repräsentiert. Dieser Zustand stellt dabei das Ergebnis der Fusion von Informationen dar, welche von unterschiedlichen Sensoren, zu verschiedenen Zeitpunkten und in wechselnden Situationen ermittelt werden können. Bei dieser Heterogenität kann nicht ausgeschlossen werden, dass erworbene Informationen sich teilweise widersprechen, veraltet oder in Kombination nicht realisierbar sind. Um solche Zustände im Weltmodell zu vermeiden, werden regelmäßig Qualitätsprüfungen durchgeführt [Ghe08, Ghe10b]. Dabei wird zwischen Konsistenzprüfungen, Gültigkeitsprüfungen, Relevanzprüfungen und Aktualitätsprüfungen unterschieden [Ghe10b].

Konsistenzprüfungen setzen semantische Einschränkungen an die möglichen Konfigurationen einer Szene mit dem Ziel um, nur gültige Umgebungszustände im Weltmodell zu repräsentieren [Ghe08]. Dabei sollen unter anderem grundlegende physikalische Gegebenheiten modelliert werden, beispielsweise, dass Gegenstände nicht in der Luft schweben oder zwei Gegenstände nicht denselben Raum einnehmen können. Konsistenzprüfungen sollten bei jeder Integration neuer Umgebungsinformationen durchgeführt werden, können aus Performanzgründen allerdings auch periodisch angestoßen werden. Neben Konsistenzprüfungen können zur Wahrung der Qualität der repräsentierten Umgebungsinformation weitere Prüfungen durchgeführt werden. Gültigkeitsprüfungen betreffen dabei die formale Korrektheit der Informationsrepräsentation. Relevanzprüfungen betreffen die Signifikanz neuer Umgebungsinformationen in Bezug auf die aktuellen Aufgaben des kognitiven Systems. Aktualitätsprüfungen betreffen schließlich die Frage, ob die repräsentierten Informationen noch aktuell sind und stoßen gegebenenfalls eine Wiederbestätigung der Informationen an [Ghe10b]. Alle Prüfungen werden dabei über entsprechende Regeln realisiert. Weitere Details

zu Qualitätsprüfungen geben die entsprechenden Vorarbeiten von Gheta et al. [Ghe08, Ghe10b].

5.3.4 Verwaltung von Relationen

Die meisten bisherigen Veröffentlichungen über das objektorientierte Umweltmodell konzentrieren sich beim Thema Informationsverwaltung auf die Verwaltung von Repräsentanten und deren Zuordnung zu den Konzepten des Hintergrundwissens. Repräsentanten setzen dabei eine objektbasierte Strukturierung der über die Umgebung erworbenen Informationen um. Relationen zwischen Repräsentanten werden in der objektorientierten Umweltmodellierung dagegen detaillierter nur im Kontext der Situationsanalyse von Fischer [Fis11, Fis12, Fis16] betrachtet. Diese ist allerdings bereits als eine dem Umweltmodell nachgelagerte Verarbeitungskomponente ausgelegt. Um in dieser Arbeit eine möglichst allgemeine Darstellung des Themas der Informationsverwaltung geben zu können, fließen an dieser Stelle einige grundlegende Betrachtungen zur Verwaltung von Relationen in der objektorientierten Umweltmodellierung ein. Diese Betrachtungen sind dabei an den Prinzipien des objektorientierten Umweltmodells sowie am Vorgehen zur Verwaltung von Repräsentanten orientiert. Weiterhin berücksichtigen sie die grundlegenden Festlegungen von Metamodell bzw. Kern-Ontologie. Diese erlauben z. B. eine strukturierte Betrachtung der Thematik im Hinblick auf unterschiedliche Szenarmodi für Relationen. Die in dieser Arbeit angestellten Betrachtungen verbleiben allerdings bis auf einzelne Beispiele ihrer Ausrichtung nach abstrakt. Eine tiefere Auseinandersetzung mit dem Thema, z. B. in Bezug auf die konkrete Verwaltung einzelner Relationen mit bestimmter Bedeutung, liegt außerhalb des Rahmens dieser Arbeit.

Unterscheidung von Relationen nach Szenarmodus

Prinzipiell lassen sich wie für Attribute auch bei Relationen verschiedene Modi der Anwendung unterscheiden. Relationen können dabei in einem perceptiven, deduktiven oder semantischen Szenarmodus verwendet werden.

Für Relationen im perceptiven Szenarmodus kann die Existenz einer Beziehung zwischen Entitäten direkt über Sensoren erfasst werden [Fis12]. Dies ist in der Praxis allerdings weniger häufig der Fall. Häufiger muss über die Existenz von Relationen auf Grundlage von Repräsentanten entschieden werden unter Verwendung der Verteilungen ihrer perceptiven und deduktiven Attribute. In diesem Fall besitzen derart inferierte Relationen einen deduktiven Szenarmodus. Sie dienen der Weiterverarbeitung von Informationen und können beispielsweise als Basisvokabular zur Definition von höherwertigen Abstraktionen wie Aufgaben und Situationen genutzt werden [Fis11]. Als Beispiele für solche deduktive Relationen lassen sich räumliche Beziehungen nennen („x steht auf y“, „x liegt links von y“) sowie Inklusionsbeziehungen („x befindet sich in y“).

Schließlich lassen sich noch Relationen mit semantischem Szenarmodus unterscheiden, deren Existenz sich aus der Klassenzugehörigkeit von Repräsentanten ergibt. Diese Relationen verkörpern dabei Vorwissen, welches in Form von Relationen zwischen Konzepten bereits im Hintergrundwissen modelliert ist. Auf Repräsentanten, welche als Instanzen eines derartigen Konzepts angesehen werden, gehen diese modellierten Relationen somit automatisch über. Als Beispiele solcher semantischer Relationen lassen sich Rollen und Funktionen nennen („x dient als y“, „x besitzt Funktion y“) sowie Teile-Ganzes Beziehungen („x ist Teil von y“).

Erzeugung neuer Relationen

Die Erzeugung von Relationen ist Teil der Informationsverwaltung im objektorientierten Umweltmodell. Relationen werden dabei in Abhängigkeit ihres Szenarmodus erzeugt. Semantische Relationen ergeben sich beispielsweise ereignisgetrieben aufgrund der Zuordnung eines Repräsentanten zu einem Konzept. Perceptive und deduktive Relationen stellen dagegen Aussagen über bestimmte, in der beobachteten Umgebung vorliegende Beziehungen zwischen Entitäten dar. Dementsprechend bilden die Eigenschaften dieser Entitäten, dargestellt als die Attribute von Repräsentanten, die Grundlage für die Entscheidung über die Erzeugung solcher Relationen.

Perzeptive Relationen Für perzeptive Relationen wird diese Entscheidung bereits in entsprechenden Sensorsystemen getroffen, also dem Umweltmodell vorgelagert. Dabei müssen dem Weltmodell alle notwendigen Informationen zu einer zu erzeugenden Relation geliefert werden: Art und Typ der Beziehung, die an ihr beteiligten Entitäten sowie die Eigenschaften der Beziehung, inklusive der durch den Sensor bestimmten Existenzwahrscheinlichkeit. Art und Typ der Beziehung werden dabei in Form von im Hintergrundwissen modellierten Relationskonzepten beschrieben. Die an der Beziehung beteiligten Entitäten können entweder als Verweise auf bereits existierende Repräsentanten angegeben werden oder in Form von Beobachtungen. Im letzteren Fall müssen die beteiligten Repräsentanten im Weltmodell durch Datenassoziation bestimmt werden. In Abhängigkeit davon, ob bereits eine Relation gegebener Art und Typs zwischen den identifizierten Repräsentanten besteht, wird dann diese Relation entweder aktualisiert oder eine neue Relation ins Weltmodell aufgenommen.

Deduktive Relationen Im Weltmodell selbst muss nur die Erzeugung solcher Relationen betrachtet werden, welche im Hintergrundwissen als deduktiv ausgewiesen werden. Für die Erzeugung neuer deduktiver Relationen lassen sich zunächst pro Zeitschritt auf Basis der Repräsentanten im Weltmodell Relationshypothesen bestimmen, welche über Attribute beschrieben werden. Das in diesem Kontext wichtigste Attribut ist die berechnete Existenzwahrscheinlichkeit der Relationshypothese. Überschreitet diese einen festgelegten Schwellwert $\tilde{\gamma}_i$, so wird die Relationshypothese als neue Relation ins Weltmodell aufgenommen, anderenfalls wird sie verworfen. Um die Existenzwahrscheinlichkeit einer deduktiven Relation berechnen zu können, muss definiert werden, wie sich diese in Abhängigkeit der Attribute von Repräsentanten ergibt. Eine solche Festlegung erfolgt a priori im Rahmen der Domänenmodellierung, wenn entsprechende Relationskonzepte für Typen von Beziehungen im Hintergrundwissen definiert werden. Die Relationskonzepte enthalten dabei Bedingungen und Rechenvorschriften für ihre Instanzierung, d. h. für die Erzeugung entsprechender Relationen.

Probabilistische Erzeugung von Relationen Um mit der probabilistischen Informationsverarbeitung im Umweltmodell verträglich zu sein, müssen die Berechnungsvorschriften zur Erzeugung von Relationen als Funktionen über Zufallsvariablen gegeben sein. Diese Zufallsvariablen stellen die Attribute der beteiligten Repräsentanten dar. Als Ergebnis dieser Funktionen wird die Existenzwahrscheinlichkeit einer Relation berechnet.

Die direkte Definition probabilistischer Kriterien für das Vorliegen von Relationen ist nicht einfach zu bewerkstelligen. Diese Aufgabe kann selbst für Domänenexperten unintuitiv und schwierig sein. Eine Möglichkeit, diesen Prozess zu vereinfachen, besteht in einer Aufteilung der Berechnungsvorschriften in Anteile für eine probabilistische Vorverarbeitung einerseits und darauf aufsetzende Entscheidungskriterien andererseits. Entscheidungskriterien stellen dabei Funktionen dar, welche über einem relevanten Definitionsbereich Werte aus dem Intervall $[0,1]$ annehmen.

So kann z. B. eine probabilistische deduktive Relation von Typ „nahe bei“ auf Basis der Positionen der zwei beteiligten Repräsentanten definiert werden. Um die Existenzwahrscheinlichkeit der Relation zu bestimmen, können zunächst die probabilistisch repräsentierten Positionskoordinaten in eine Wahrscheinlichkeitsverteilung für den Abstand zwischen den beiden Repräsentanten umgerechnet werden. Der Abstand wird somit durch eine Zufallsvariable probabilistisch repräsentiert. Für den Abstand kann weiterhin ein nicht-probabilistisches Entscheidungskriterium angegeben werden, welches bestimmt, ob eine Relation von Typ „nahe bei“ zwischen den beiden betrachteten Repräsentanten vorliegt. Dazu kann beispielsweise ein Schwellwert genutzt werden, unterhalb dessen die Relation als vorliegend angenommen wird. Dies entspricht einer gespiegelten und verschobenen Stufenfunktion. Die Erwartung über das Vorliegen der Relation, gegeben als Erwartungswert über die Entscheidungsfunktion bzgl. des probabilistisch repräsentierten Abstands, kann dann als Existenzwahrscheinlichkeit für die Relation betrachtet werden. Auf diese Weise können z. B. räumliche Relationen definiert werden, die in den Attributen von Repräsentanten verankert sind (vgl. Abschnitt 4.4.3).

Um nicht nur binäre, sondern auch abgestufte Entscheidungen zu erlauben, bietet sich die Verwendung einer Art Zugehörigkeitsfunktion (aus dem Gebiet der unscharfen Mengen) als Entscheidungsfunktion an. Diese Funktion kann dabei als ein gemischt diskret-stetiges Transitionsmodell dienen, welches die gemeinsame Wahrscheinlichkeitsverteilung von Existenzwahrscheinlichkeit der Relation und dem Ergebnis der probabilistischen Vorverarbeitung darstellt. Die Existenzwahrscheinlichkeit kann in diesem Fall durch Berechnung des Chapman-Kolmogorov Integrals dieser Transitionsdichte mit dem Ergebnis der probabilistischen Vorverarbeitung bestimmt werden. Dies entspricht der Berechnung einer erwarteten Zugehörigkeit bzgl. des Vorverarbeitungsergebnisses.

Die Möglichkeit der oben beschriebenen Aufteilung stellt ein prinzipielles Vorgehen zur Modellierung der Existenzwahrscheinlichkeit von Relationen dar. Für einfach definierbare Relationen, wie z.B. die obige „nahe bei“ Beziehung, kann dieses Vorgehen wie beschrieben angewendet werden. Für nur komplexer beschreibbare Relationen kann es erforderlich sein, dieses Vorgehen zu erweitern. Eine Möglichkeit ist es dabei, mehrere Teil-Entscheidungskriterien zu definieren, die jeweils auf Basis einer probabilistischen Teil-Vorverarbeitung basieren, und die Ergebnisse dieser Teilkriterien dann unter Anwendung entsprechender Operatoren zu kombinieren. Zu diesem Zweck können z.B. Operatoren der Fuzzy Logik genutzt werden.

Zur Erzeugung von Relationen (bzw. Relationshypothesen) eines bestimmten Typs können in jedem Zeitschritt die im Weltmodell enthaltenen Repräsentanten gegen im Hintergrundwissen definierte Relationskonzepte verglichen werden. Die berechnete Existenzwahrscheinlichkeit für eine Relation lässt sich dabei als eine bedingte Wahrscheinlichkeit verstehen. Die Wahrscheinlichkeit ist dabei bedingt auf die Existenz der beteiligten Repräsentanten. Die tatsächliche Existenzwahrscheinlichkeit ergibt sich schließlich als das Produkt dieser bedingten Existenzwahrscheinlichkeit mit den Existenzwahrscheinlichkeiten aller beteiligten Repräsentanten. Überschreitet diese tatsächliche Wahrscheinlichkeit den Schwellwert $\bar{\gamma}_i$, so wird die Hypothese

als neue Relation ins Weltmodell aufgenommen, anderenfalls wird die Hypothese verworfen.

Die Erzeugung neuer semantischer Relationen erfolgt ebenfalls auf Grundlage der im Weltmodell enthaltenen aktualisierten Repräsentanten, basierend auf deren Repräsentant-zu-Konzept Zuordnung. Wird diese erstmalig für einen neu zum Weltmodell hinzugefügten Repräsentanten berechnet oder ändert sich für einen Repräsentanten das zugeordnete Konzept, so werden Hypothesen über neue semantische Relationen für die entsprechenden Repräsentanten erzeugt. Die Existenzwahrscheinlichkeiten dieser Relationshypothesen ergeben sich dabei aus den Unsicherheiten der Repräsentant-zu-Konzept Zuordnung für das entsprechende Konzept. Liegen diese über $\tilde{\gamma}_i$, so werden auch hier die Hypothesen als neue Relationen ins Weltmodell aufgenommen, und anderenfalls verworfen.

Aktualisierung von Relationen

Neben der Erzeugung von Relationen zählt auch die Aktualisierung existierender Relationen zu den Aufgaben der Informationsverwaltung. Da alle in Relationen enthaltenen Informationen allerdings auf den Attributen der Repräsentanten des Weltmodells basieren, bietet eine Aktualisierung von Relationen durch eine probabilistische Informationsverarbeitung im Allgemeinen keinen informationsbezogenen Mehrwert, z. B. im Sinne einer reduzierten Unsicherheit. Dieselben Informationen lassen sich in gleicher Weise durch die standardmäßig ausgeführte Aktualisierung der Repräsentanten und eine anschließende Neuberechnung der Relationen gewinnen. Dies betrifft auch die zeitliche Fortschreibung von Relationen. Allerdings gibt es Anwendungsfälle, in denen eine probabilistische Weiterverarbeitung von Relationen aus anderen Gründen vorteilhaft sein kann, z. B. um eine Glättung in der zeitlichen Entwicklung der Informationen zu erreichen [Fis16].

Für die zeitliche Fortschreibung der Existenzwahrscheinlichkeit einer Relation ergibt sich der exakte Wert durch Neuberechnung, nachdem die zeitliche Fortschreibung aller Repräsentanten im Weltmodell erfolgt ist. In diese Berechnung gehen dann direkt die gealterten Attributverteilungen und

Existenzwahrscheinlichkeiten der Repräsentanten ein. Für semantische Relationen muss zuvor die Repräsentant-zu-Konzept Zuordnung auf Basis der aktualisierten Repräsentanten ebenfalls neu berechnet werden.

Als Alternative kann ein approximativer Ansatz zur zeitlichen Fortschreibung der Existenzwahrscheinlichkeit gewählt werden, welcher analog zur Alterung von Repräsentanten ausgelegt ist. Bei diesem Ansatz muss für jedes Relationskonzept ein entsprechender Alterungsfaktor definiert werden, welcher die Abnahme der Existenzwahrscheinlichkeit der Relation pro Zeitschritt beschreibt. Für die zeitliche Fortschreibung der Relation wird ihre Existenzwahrscheinlichkeit dann zunächst anhand dieses Alterungsfaktors gemindert. Um ein einheitliches Vorgehen im Vergleich zur Erzeugung von Relationen zu gewährleisten, muss die geminderte Existenzwahrscheinlichkeit anschließend noch mit den Alterungsfaktoren der an der Relation beteiligten Repräsentanten multipliziert werden, der Abnahme ihrer Existenzwahrscheinlichkeiten durch Alterung Rechnung tragend. Die Alterungsfaktoren semantischer Relationen werden hierbei häufig den Wert 1 annehmen, da die Existenz der Relationen bereits im Hintergrundwissen modelliert wurde und somit als statisch angesehen werden kann. Dieser alternative Ansatz ist allerdings in dem Sinne approximativ, als dass die berechneten Werte nicht notwendigerweise mit den sich durch Neuberechnung ergebenden Werten übereinstimmen müssen. Der Alterungsfaktor einer Relation ist agnostisch z. B. für die Typen der an einer Relation beteiligten Repräsentanten sowie für die zeitliche Fortschreibung der enthaltenen deskriptiven Attribute. Dies führt zu einer Inkonsistenz der im Weltmodell repräsentierten Informationen, welcher ein reduzierter Berechnungsaufwand für Relationen gegenübersteht. Abhängig vom Anwendungsfall kann dies eine gewünschte Situation sein.

Entfernen von Relationen

Ein weiterer Punkt der Verwaltung von Relationen ist die Entfernung von nicht mehr als relevant angesehenen Relationen aus dem Weltmodell. Dabei lässt sich dasselbe Vorgehen wie bei Repräsentanten anwenden: sinkt

die Existenzwahrscheinlichkeit einer Relation unter einen Schwellwert $\tilde{\gamma}_e$, so gilt diese als nicht mehr relevant und wird aus dem Weltmodell entfernt. Eine durch einen weiteren Schwellwert ausgelöste Wiederbestätigung ist im Falle von Relationen nur bedingt sinnvoll, da sich die Existenzwahrscheinlichkeit einer Relation direkt aus den Attributen der beteiligten Repräsentanten ergibt. Sinnvoll könnte in einem solchen Fall das Durchreichen der Wiederbestätigungsanforderung an die beteiligten Repräsentanten sein. Weiterhin müssen auch diejenigen Relationen aus dem Weltmodell entfernt werden, welche sich auf Repräsentanten beziehen, die ihrerseits nicht mehr im Weltmodell enthalten sind. Dies kann erfolgen, indem beim Entfernen eines Repräsentanten aus dem Weltmodell zugleich alle Relationen entfernt werden, an welchen der Repräsentant beteiligt war.

Aus dem Weltmodell entfernte Relationen werden, analog zu entfernten Repräsentanten, in der Zustandshistorie des Umweltmodells archiviert. Auch für Relationen sind dabei anwendungsbezogene Unterscheidungen desjenigen Werts vorstellbar, welchen die Archivierung einer Relation eines bestimmten Typs darstellt. Dieser Wert kann dabei a priori in den Relationskonzepten hinterlegt werden. Beispielsweise kann die Information, dass sich ein bestimmter Gegenstand innerhalb eines anderen Gegenstandes (z. B. in einem Behälter) befindet, hilfreich sein, wenn es gilt diesen ersten Gegenstand aufzufinden. Dies könnte in einer Situation auftreten, in welcher zunächst Repräsentanten für beide Gegenstände im Weltmodell enthalten sind und der erste Gegenstand zu einem gewissen Zeitpunkt in den anderen Gegenstand gestellt wird. Dabei wird eine entsprechende „befindet sich in„ Relation erzeugt. Wird nun der erste Gegenstand über eine gewisse Zeitspanne nicht mehr wahrgenommen, weil beispielsweise der zweite Gegenstand nicht eingesehen werden kann, wird der entsprechende Repräsentant aus dem Weltmodell entfernt. Bleibt die erstellte Relation durch Archivierung erhalten, so kann diese nun zum Auffinden des ersten Gegenstandes genutzt werden, beispielsweise wenn ein Nutzer nach diesem verlangt. Dieses Auffinden kann in der dargestellten Situation auch durch die Archivierung des Repräsentanten für den ersten Gegenstand, samt seiner zuletzt bekannten Position, gelöst werden. Allerdings stellt die archivierte Relation in diesem Fall eine Information mit höherem Nutzwert dar.

Dieses Beispiel illustriert weiterhin, dass es ebenfalls ein gewinnbringender Ansatz sein kann, Relationen erst dann aus dem Weltmodell zu entfernen, wenn keiner der beteiligten Repräsentanten mehr im Weltmodell vorhanden ist. Diesem Prinzip folgend ist das Auffinden des ersten Gegenstandes aus obigem Beispiel ebenfalls unkompliziert möglich. Die Archivierung von Relationen in der Zustandshistorie erlaubt es ebenfalls, aus den bisher aufgetretenen Relationen zu lernen. Dabei können z. B. häufig für Repräsentanten eines bestimmten Typs auftretende Relationen als Vorwissen in die entsprechenden Konzeptklassen übernommen werden.

Qualitätsprüfungen für Relationen

Als letzten Punkt der Verwaltung von Relationen müssen diese wie Repräsentanten auch Qualitätsprüfungen unterzogen werden. Abgesehen von Aktualitätsprüfungen lassen sich dabei dieselben Arten von Prüfungen wie bei Repräsentanten anwenden. Die Ansätze für Relevanz- und Gültigkeitsprüfungen können dabei direkt auf Relationen übertragen werden. Für Konsistenzprüfungen, durch welche semantisch ungültige Konfigurationen im Weltmodell verhindert werden sollen, lassen sich einige für Relationen spezifische Erweiterungen einführen. In den Relationskonzepten im Hintergrundwissen können dabei Eigenschaften der modellierten Beziehungen hinterlegt werden wie Symmetrie, Anti-Symmetrie, Transitivität oder Anti-Transitivität. Dass diese Eigenschaften auch durch die im Weltmodell enthaltenen Relationen zwischen Repräsentanten erfüllt werden, kann dann durch entsprechende Konsistenzprüfungen sichergestellt werden.

Für antisymmetrische Beziehungen kann z. B. sichergestellt werden, dass im Weltmodell nicht mehrere Relationen desselben Typs über derselben Menge von Repräsentanten existieren. Dies gilt analog für antitransitive Relationen. Für transitive Relationen könnte weiterhin umgesetzt werden, dass implizite, sich aus der Transitivität der Beziehung ergebende Relationen zwischen Repräsentanten auch explizit im Weltmodell enthalten sind.

5.3.5 Zeitlicher Ablauf

Die in diesem Abschnitt dargestellte Informationsverwaltung des objektorientierten Umweltmodells umfasst zahlreiche, teils voneinander abhängige Aufgaben. An dieser Stelle soll zusammenfassend ein möglicher zeitlicher Ablauf der Operationen der Informationsverwaltung dargelegt werden, der zum Vorgehen in dieser Arbeit passt. Dieser zeitliche Ablauf stellt eine Detaillierung des in Abschnitt 5.1.1 überblicksweise dargestellten Verarbeitungsschemas dar. Im Speziellen werden dabei Aspekte der Datenassoziation und der Verwaltung von Relationen in das bisherige Verarbeitungsschema integriert. Folgende Operationen werden dabei in einem Zeitschritt t_k nacheinander ausgeführt:

- Zeitliche Fortschreibung der Repräsentanten (inklusive der Entitätshypothese r_0) auf den aktuellen Zeitschritt t_k
- Bei Vorliegen einer Beobachtung \hat{y}_k für den aktuellen Zeitschritt:
 - Berechnung der Datenassoziationsverteilung d_k
 - Anteilige Aktualisierung der Repräsentanten (inklusive Entitätshypothese) auf Basis der berechneten Assoziationsverteilung
 - Gegebenenfalls: Aufwerten der Entitätshypothese zum Repräsentant im Weltmodell und Initialisierung neuer Entitätshypothese
- Entfernen von nicht mehr als relevant betrachteten Repräsentanten aus dem Weltmodell
- Durchführung von Qualitätsprüfungen für Repräsentanten, welche keine Informationen über deren Klassenzugehörigkeit benötigen (z. B. Gültigkeitsprüfungen, Aktualitätsprüfungen)
- Klassifizierung von Repräsentanten (Berechnung der Repräsentant-zu-Konzept Zuordnung)
- Durchführung von Qualitätsprüfungen für Repräsentanten mit Wissen über Klassenzugehörigkeit (z. B. Konsistenzprüfungen, Relevanzprüfungen)

- Entfernen von Relationen, welche aktuell nicht mehr im Weltmodell enthaltene Repräsentanten betreffen
- Aktualisierung der existierenden Relationen (z.B. durch Neuberechnung) auf Basis der aktualisierten Repräsentanten
 - Gegebenenfalls: Entfernen nicht mehr relevanter Relationen
- Erzeugen neuer Relationen: Prüfung, ob für geänderte oder neu aufgenommene Repräsentanten weitere Relationen vorliegen
- Durchführung von Qualitätsprüfungen für Relationen

Der dargestellte Ablauf stellt dabei zunächst sicher, dass eine minimale Menge von als relevant betrachteten aktualisierten, konsistenten und formal gültigen Repräsentanten im Weltmodell enthalten ist, bevor die auf dieser Menge von Repräsentanten basierenden Relationen betrachtet werden. Dieser Ablauf wird prinzipiell in jedem Zeitschritt wiederholt. Im Rahmen von Laufzeitoptimierungen können einzelne Schritte nur zu bestimmten Zeitpunkten durchgeführt werden, wie bereits in Abschnitt 5.1.1 erläutert. Zu diesen einzelnen Schritten zählen auch die Verarbeitungsoperationen der adaptiven Umweltmodellierung, welche in späteren Kapiteln vorgestellt werden. Nachfolgend soll zunächst näher auf das Thema des Entfernens von Informationen aus dem Weltmodell eingegangen werden. Dies betrifft Fragestellungen wie wann das Archivieren von zu entfernenden Informationen nützlich sein kann, vor allem in Bezug auf das Lernen von Erfahrungswerten.

5.4 Speicherung von Erfahrungsinformationen

Mit Weltmodell und Hintergrundwissen besitzt das objektorientierte Umweltmodell zwei Komponenten, welche es einem kognitiven System erlauben, aktuelle Informationen und Wissen bei Bedarf abzurufen sowie für eine spätere Verwendung persistent abzulegen. Im Hintergrundwissen wird dabei allgemeines Vorwissen gespeichert, welches statische Eigenschaften der

relevanten Umgebung sowie der auszuführenden Aufgabenstellungen betrifft. Das Weltmodell repräsentiert dagegen zu jedem Zeitpunkt den aktuellen Zustand der beobachteten Umgebung. Veränderungen an diesem Zustand, und somit die Dynamik der betrachteten Umgebung, werden durch die Speicherung vergangener Zustände mit dem jeweiligen Zeitbezug in einer Zustandshistorie realisiert [Ghe08]. Diese Zustandshistorie ermöglicht dabei einerseits die Behandlung von Aufgaben, welche Informationen aus verschiedenen Zeitabschnitten benötigen [Ghe08], und stellt andererseits ein Protokoll der erworbenen Informationen dar. Diese Informationen liegen in der Zustandshistorie jedoch zunächst in roher, unaufbereiteter Form vor. Aus der Zustandshistorie können jedoch die als wertvoll angesehenen Informationen extrahiert und unter Verwendung entsprechender Lernprozesse zu neuem domänen- und aufgabenspezifischen Erfahrungswissen aufbereitet werden [Ghe10a].

Auf ein Vorgehen zum Erwerb von klassenbezogenem Hintergrundwissen für bisher nicht modellierte Entitätstypen wird im Kapitel 8 mit Bezug zur adaptiven Umweltmodellierung eingegangen. In diesem Abschnitt sollen zunächst Möglichkeiten vorgestellt und erörtert werden, wie sich ein kognitives System durch Erwerb von Erfahrungswissen an seine Umgebung anpassen und sich bei der Durchführung der ihm auferlegten Aufgaben verbessern kann. In vorausgehenden Abschnitten wurde bereits im Rahmen der Verwaltung von Repräsentanten und Relationen die Möglichkeit angesprochen, erworbenes Erfahrungswissen über relevante Entitäten für eine längerfristige Aufbewahrung vorzusehen, beispielsweise durch Archivierung oder Integration ins Hintergrundwissen des Umweltmodells. Diese Möglichkeiten sollen an dieser Stelle durch eigene Ideen vertieft und strukturiert diskutiert werden, unter Einbeziehung und Zusammenfassung der Aussagen von Vorarbeiten zur objektorientierten Umweltmodellierung. Die Strukturierung soll dabei anhand der Art der erworbenen Erfahrungsinformationen und den damit verbundenen Möglichkeiten und Orten zur Speicherung von Informationen stattfinden. Es sei angemerkt, dass im Rahmen dieser Arbeit keine Evaluierung der hier vorgestellten Überlegungen durchgeführt wurde.

Arten von Erfahrungsinformationen und ihre Speicherorte

Die Repräsentation des Umgebungszustandes im Weltmodell unterliegt wie bereits erwähnt einer Anforderung zur Schlankhaltung. Umgesetzt wird diese Anforderung durch das Entfernen von nicht mehr relevanten Repräsentanten und Relationen aus dem Weltmodell. Weiterhin wird im Weltmodell der Zustand zum aktuellen Zeitpunkt repräsentiert, die zeitliche Entwicklung dieses Zustands dagegen wird in der Zustandshistorie dargestellt. Diese Zustandshistorie ist dabei Sammelbecken sämtlicher über die Umgebung erworbener Informationen und daher Ausgangspunkt für die Selektion und Extraktion relevanten Erfahrungswissens. Als Senke solches aufbereiteten Wissens bietet sich das Hintergrundwissen an. Hier können einerseits existierende Konzepte um domänenspezifisches Erfahrungswissen ergänzt oder durch Unterklassenbildung spezialisiert werden. Andererseits kann hier auch Wissen über einzelne, herausragende Entitäten in Form der bereits erwähnten prioren Instanzen abgelegt werden.

Speicherorte Zusätzlich zu Weltmodell, Zustandshistorie und Hintergrundwissen bietet sich die Nutzung eines Kurzzeitspeichers als Speicherort für aktuelle Erfahrungsinformationen an. Dieser Kurzzeitspeicher betrifft Informationen, welche zwar aus dem Weltmodell entfernt wurden, in der näheren Zukunft aber mit einer gewissen Wahrscheinlichkeit wieder relevant werden können. Werden derartige Informationen in einem Kurzzeitspeicher abgelegt, so können diese bei Bedarf schnell wieder zugegriffen werden. Somit lässt sich insgesamt eine Art Speicherhierarchie für Zustandsinformationen umsetzen: an der Spitze steht das Weltmodell mit zeitaktuellen Informationen, gefolgt von einem Kurzzeitspeicher für potentiell in der nahen Zukunft relevante Informationen. Ergänzt wird die Hierarchie durch die Zustandshistorie, welche alle bisher über die Umgebung erworbenen Informationen in Form eines Protokolls ungefiltert und unaufbereitet darstellt. Vervollständigt wird die Hierarchie schließlich durch das Hintergrundwissen, welches das über einen aktuellen Anwendungsfall hinaus gültige Erfahrungswissen persistiert. Zustandshistorie, Kurzzeitspeicher und Hintergrundwissen übernehmen dabei die Funktion der Archivierung relevanter erworbener Informationen, welche aus dem Weltmodell entfernt wurden.

Passend zu diesen unterschiedlichen Arten von Informationsspeichern lassen sich auch Arten besonders relevanter Erfahrungsinformationen identifizieren.

Einzigartige Entitäten Eine besonders relevante Art von Entität stellen dabei solche Entitäten dar, welche in der betrachteten Umgebung als einzigartig anzusehen sind. Dies betrifft Entitäten, welche klar unterscheidbare Instanzen eines i. A. umfassenden Entitätstyps sind und die weiterhin eine hohe Relevanz für den aktuellen Anwendungsfall besitzen, indem sie beispielsweise häufig für Aufgaben benötigt werden. Da der Entitätstyp umfassend ist, wird seine Modellierung als Konzept im Hintergrundwissen oft nicht die Angabe von sehr spezifischen Attributen erlauben. Die beobachteten Attributwerte einer der Instanzen dieses Typs stellen somit eine wertvolle Spezialisierung dar. Als Beispiele solcher Entitäten lassen sich menschliche Nutzer oder beobachtete Personen zusammen mit z. B. ihren Vorlieben und Gewohnheiten nennen. Weiterhin fallen auch Entitäten in diese Kategorie, welche als die einzigen in einer betrachteten Umgebung auftretenden Instanzen eines Konzepts gelten können. Hier lassen sich als Beispiele aus der Haushaltsdomäne ein Kühlschrank oder ein Küchentisch nennen, welche in der Regel nur einmal als Objekt in einer Küche auftreten. Einmal erworbene konkrete Informationen über solche Entitäten besitzen ebenfalls einen hohen Nutzwert für ein kognitives System. Die objektorientierte Umweltmodellierung behandelt solche Entitäten als sog. *prioren Instanzen*¹ [Bel09, Ghe10a]. Diese werden zur Laufzeit des Systems im Weltmodell vorgehalten und können initial aus dem Hintergrundwissen geladen werden. Zur langfristigen Persistierung können Änderungen an *prioren Instanzen* wieder ins Hintergrundwissen zurückgespielt werden. *Priore Instanzen* sind weiterhin gute Kandidaten, um im vorgeschlagenen Kurzzeitspeicher vorgehalten zu werden. Dies betrifft z. B. den Fall, dass ein Kontextwechsel im kognitiven System erfolgt, welcher in der Zukunft auch wieder rückgängig gemacht werden könnte – wie z. B. das Wechseln in einen anderen Raum in einer Haushaltsumgebung.

¹ Englisch: prior records [Bel09]

Stellvertreter-Entitäten Weiterhin kann es in einer Domäne Entitäten geben, die zwar nicht die einzigen Instanzen einer Klasse sind, die aber dennoch eine ausgezeichnete Position einnehmen, in Form einer Art Stellvertreterfunktion für ihr Konzept. Beispiele aus der Haushaltsdomäne sind verderbliche Verbrauchsgegenstände, die nach ihrer Öffnung nicht instantan, sondern erst allmählich verbraucht werden – wie eine Packung Milch, eine Flasche Saft oder eine Packung Müsli. Spricht der Mensch von solchen Objekten oft auch nur unspezifisch, so ist meistens dennoch eine ganz bestimmte Instanz gemeint. Vorgehaltene Informationen über solch ausgezeichnete Instanzen sind meistens bzgl. zustandsbezogener Attribute relevant, wie die letzte bekannte Position einer Instanz, ihr Alter oder der Anteil ihres bereits verbrauchten Inhalts. Daher lohnt es sich auch hier für ein kognitives System, erworbene Informationen zu solchen Instanzen zumindest mittelfristig vorzuhalten. Aufgrund ihrer zustandsbehafteten Natur ist eine langfristige Speicherung im Hintergrundwissen nicht notwendigerweise zweckdienlich. Hier bietet sich dagegen wieder der Kurzzeitspeicher als Speicherort an. Für welche Typen von Entitäten eine derartige Vorhaltung im Kurzzeitspeicher sinnvoll ist, hängt im Allgemeinen von den Aufgaben des kognitiven Systems ab und kann, wie in Abschnitt 5.3.2 beschrieben, bereits a priori über Konzepte festgelegt werden.

Instanzen domänenspezifischer Unterklassen Ähnlich zu einzigartigen Entitäten stellen auch Instanzen domänenspezifischer Unterklassen Entitäten dar, welche im Hintergrundwissen bereits über ein allgemeiner gehaltenes Konzept beschrieben werden. Im Gegensatz zu einzigartigen Entitäten können zu diesen Konzepten in einer Anwendung allerdings mehrere Instanzen gleichzeitig existieren. Als Beispiele für solche Konzepte aus der Haushaltsdomäne lassen sich Gebrauchsgegenstände wie Tafelbesteck oder Geschirr nennen. Im Hintergrundwissen mag z. B. ein allgemeines Konzept für Tafelmesser modelliert sein. In einer Küchenumgebung können unterschiedliche Instanzen dieses Konzepts beobachtet werden. Für diese konkret beobachteten Instanzen kann nun eine wesentlich spezifischere Modellierung möglich sein, z. B. in Bezug auf ihre Form, Größe und Farbe, als im allgemeinen Konzept. Um solches, ebenfalls wertvolles Erfahrungswissen speichern zu können, besteht eine Möglichkeit darin, das allgemeinere Konzept

im Hintergrundwissen um eine spezialisierte Unterklasse zu ergänzen. Diese Unterklasse kann dann die spezifisch ausgeprägten Eigenschaften beobachteter Instanzen durch konkretisierte Attributverteilungen beschreiben. Die Erzeugungen solcher Unterklassen lässt sich mit den Mitteln der in Kapitel 8 beschriebenen adaptiven Wissensverwaltung umsetzen.

Typbezogenes Zusatzwissen Neben der Erzeugung neuer Unterklassen kann domänenspezifisches Erfahrungswissen auch in Form einer Ergänzung existierender Konzepte gespeichert werden. Dies betrifft z. B. Informationen wie den in einer Umgebung üblichen Aufbewahrungsort von Gegenständen, in einem Haushaltsszenario beispielsweise den Aufbewahrungsort von Geschirrtellen wie Tassen und Tellern oder Verbrauchsgütern wie Obst. Auch die maximal verfügbare Anzahl von Gegenständen, wie beispielsweise Geschirrtellen, kann nützlich Erfahrungswissen darstellen und als typbezogenes Zusatzwissen im entsprechenden Konzept gespeichert werden.

Funktionen eines Kurzzeitspeichers Der vorgeschlagene Kurzzeitspeicher kann genutzt werden, wenn als Ergebnis der Datenassoziation für eine gegebene Beobachtung ein neuer Repräsentant zu erzeugen ist. In diesem Fall können nun die Beobachtungswerte zunächst mit den im Kurzzeitspeicher vorgehaltenen Repräsentanten verglichen werden. Bei Übereinstimmung kann der entsprechende Repräsentanten mitsamt seinen bisherigen Attributen reaktiviert, d. h. wieder ins Weltmodell aufgenommen, und anhand der gegebenen Beobachtung aktualisiert werden. Somit lassen sich bereits erworbene Erfahrungsinformationen, welche zwischenzeitlich entfernt und archiviert wurden, wiederverwenden. Der Vergleich zwischen Beobachtung und archivierten Repräsentanten im Kurzzeitspeicher kann mittels der normalen Datenassoziation erfolgen. Weiterhin lässt sich der Inhalt des Kurzzeitspeichers auch für andere, auf Effizienz optimierte Verarbeitungsoperationen nutzen, wie beispielsweise die Beantwortung von Nutzeranfragen nach dem Aufenthaltsort von Entitäten. Wurden diese bereits aus dem Weltmodell entfernt, erlaubt auch hier der Kurzzeitspeicher einen gegenüber der Zustandshistorie verkürzten Zugriff.

Ähnliches gilt auch für Relationen. Auch diese können zur Beschleunigung des Zugriffs nach Entfernung aus dem Weltmodell in den Kurzzeitspeicher

aufgenommen werden. Dies ist vor allem dann sinnvoll, wenn Relationen aufgrund eines nicht mehr im Weltmodell existierenden Repräsentanten entfernt werden. In diesem Fall kann der entsprechende Repräsentant zugleich in den Kurzzeitspeicher aufgenommen werden.

Verarbeitung von prioren Instanzen

Priore Instanzen erlauben es, Vorwissen über bestimmte Entitäten, im Gegensatz zu Vorwissen über Entitätstypen, in das objektorientierte Umweltmodell einzubringen. Dieses instanzbasierte Vorwissen kann dabei ebenfalls a priori von menschlichen Experten modelliert werden [Bel09]. Dem kognitiven System wird somit die Möglichkeit gegeben, bei Beobachtung bestimmter Entitäten direkt über eine Menge von vorab definierten, größtenteils semantischen Informationen zu verfügen [Ghe10a]. Weiterhin kann es möglich sein, perzeptive Attribute in prioren Instanzen umfassender und präziser zu modellieren als es durch die Verwendung der Sensoren eines kognitiven Systems möglich sein könnte. Priore Instanzen ermöglichen in diesem Fall eine Präzisierung und Detaillierung von Attributen auf Basis von Vorwissen [Ghe10b, Bel12b].

Für die Verwendung von prioren Instanzen ist es eine wichtige Fragestellung, wie die im Hintergrundwissen modellierten prioren Instanzen mit beobachteten Entitäten in Verbindung gebracht werden können. Hier können unterschiedliche Situationen vorliegen. Eine Möglichkeit ist, dass priore Instanzen z. B. nicht manuell von Domänenexperten erstellt wurden, sondern zu einem früheren Zeitpunkt als Repräsentanten im Weltmodell erzeugt und anschließend ins Hintergrundwissen übertragen wurden. In diesem Fall kann der zuvor beschriebene Mechanismus zur Datenassoziation genutzt werden. Durch die Datenassoziation kann eine Entitätsbeobachtung einer prioren Instanz zugeordnet werden, falls priore Instanzen zusammen mit den Repräsentanten des Weltmodells durch die Datenassoziation als mögliche Zuordnungsziele betrachtet werden. Wurde eine priore Instanz manuell modelliert, so kann ebenfalls der Mechanismus zur Datenassoziation genutzt werden, falls die priore Instanz mit ausreichend diskriminativen perzeptiven

Attributen modelliert wurde. Sollen nicht Entitätsbeobachtungen mit prioren Instanzen in Verbindung gebracht werden, sondern deren Weiterverarbeitung in Form eines Repräsentanten des Weltmodells, so kann hierfür die in Kapitel 6 beschriebene Repräsentant-zu-Konzept Zuordnung verwendet werden. Weiterhin kann eine priore Instanz auch immer durch einen Benutzer einer Beobachtung bzw. einem Repräsentanten zugeordnet werden, z. B. mittels eines eindeutigen Identifikators wie einem Namen. Eine solche Zuordnung könnte z. B. über Sprachbefehle erfolgen.

Über die hergestellte Zuordnung zwischen einem Repräsentanten und einer prioren Instanz können auch die perzeptiven Attribute der prioren Instanz aktualisiert werden. Sinkt die Existenzwahrscheinlichkeit des Repräsentanten unter die Schwelle γ_e , wird die Verbindung zur prioren Instanz getrennt und der Repräsentant aus dem Weltmodell entfernt. Sollen Entitäten eines bestimmten Typs immer als priore Instanzen im Hintergrundwissen persistiert werden (z. B. singuläre Instanzen), so kann diese Eigenschaft im Konzept für den entsprechenden Entitätstyp bereits a priori annotiert werden. Zu diesem Zweck müsste die Kern-Ontologie des objektorientierten Umweltmodells entsprechend erweitert werden, um eine derartige Annotation von Konzepten im Hintergrundwissen darstellen zu können.

Lernen aus Erfahrungswerten

Neben der längerfristigen Speicherung wichtiger Entitäten ist auch die Verarbeitung und Analyse der in der Zustandshistorie gespeicherten Informationen ein wichtiger Schritt bei der Generierung und Speicherung von Erfahrungswissen. Ein wesentliches Ziel ist dabei, das bisherige Hintergrundwissen im objektorientierten Umweltmodell durch domänenspezifische Informationen zu ergänzen und zu spezialisieren. Auf Basis von in der Umgebung beobachteten Instanzen lassen sich die entsprechenden Konzepte im Hintergrundwissen um zusätzliche Attribute ergänzen oder durch neue Unterklassen spezialisieren.

Solches zusätzliches Erfahrungswissen bietet den Vorteil, sowohl die Informationsverarbeitung im Umweltmodell als auch die Bereitstellung von Informationen durch das Umweltmodell in Bezug auf die Aufgaben des kognitiven Systems verbessern und optimieren zu können. Die Erweiterung von Konzepten um domänenspezifische deduktive Attribute ermöglicht es beispielsweise, statistisches Wissen über die beobachtete Umgebung zu persistieren. Ein Beispiel solchen Wissens ist der wahrscheinlichste Aufenthaltsort von Instanzen eines Konzepts, wie ein Aufbewahrungsort für Gegenstände. Weiterhin können für Entitätstypen Präferenzen gelernt und als deduktive Attribute in Konzepten gespeichert werden, z. B. in Bezug auf auszuführende Handlungen für Gegenstände, welche prinzipiell mehrere Alternativen erlauben (in der Haushaltsdomäne z. B., für welche Geschirrranteile ein Mensch eine Reinigung durch die Spülmaschine erlaubt und für welche nicht). Darüber hinaus ermöglicht die Erzeugung domänenspezifischer Unterklassen weitere Verbesserungen, basierend auf präziser definierten Konzepten. Beispielsweise kann die Genauigkeit der Repräsentant-zu-Konzept Zuordnung verbessert werden, wenn die Attribute von allgemeiner definierten Konzepte basierend auf den bisherigen Beobachtungen der Umgebung spezialisiert werden können in einer entsprechenden Unterklasse.

Um neues Erfahrungswissen für Konzepte zu lernen, werden in der Zustandshistorie alle Repräsentanten betrachtet, welche Instanzen der entsprechenden Konzepte darstellen. Durch Analyse der Attributverteilungen dieser Repräsentanten im Vergleich zu den im Konzept modellierten Attributen lässt sich dann neues, domänenspezifisches Erfahrungswissen identifizieren und extrahieren. Ein mögliches Vorgehen zum Lernen aus Erfahrungswerten für Konzepte wird im Kapitel 8 beschrieben. Die Integration neuen Wissens sollte dabei immer mit Bedacht erfolgen und z. B. auf Prinzipien wie der Relevanz des Wissens begründet sein.

Speicherung der Zustandshistorie

Die Speicherung der Zustandshistorie kann optimiert erfolgen, indem nur diejenigen Attribute in einem Zeitschritt $k_0 + \tau$ abgespeichert werden, welche sich im Vergleich zu ihren Werten in einem Basiszeitschritt k_0 geändert haben. Eine Möglichkeit, eine solche Speicherung effizient auszuführen, besteht in der Verwendung von auf dem Markt erhältlichen Datenbanksystemen. Als Voraussetzung hierfür müssen die zu persistierenden Informationen, d. h. die Attribute der Repräsentanten bzw. die Relationen im Weltmodell, in ein vom Datenbanksystem unterstütztes Format konvertiert werden. Eine solche Konvertierung kann automatisiert ausgeführt werden. Die semantische Interoperabilität der Konvertierung wird dabei durch das in Abschnitt 4.3 definierte Metamodell unterstützt. Da sich die Entitäten unterschiedlichen Typs sowie die unterschiedlichen Relationen darin unterscheiden können, welche Attribute sie besitzen, bietet sich eine schemafreie Repräsentation der zu persistierenden Informationen an. Zu diesem Zweck kann z. B. das JSON¹ [Bra17] Format genutzt werden, um Repräsentanten und Relationen jeweils als sog. Dokumente zu repräsentieren. Solche Dokumente können anschließend in einer dokumentenorientierten Datenbank² gespeichert und bei Bedarf wieder abgerufen werden. Nachfolgend wird dieser Ansatz beispielhaft dargestellt.

Beispiel 9 (Persistierung eines Repräsentanten als JSON in k_0). *Sei ein Repräsentant r_i gegeben, welcher beispielhaft über zwei deskriptive Attribute verfügt: ein Attribut für das ordinale Merkmal Farbe und eines für das verhältnisskalierte Attribut Länge. Weiterhin seien eine Existenzvariable sowie eine Typvariable als spezielle Attribute gegeben, sowie ein Zeitstempel. Dann ergibt*

¹ JavaScript Object Notation

² Beispiele solcher Datenbanken sind: CouchDB, MongoDB.

sich in JSON die Darstellung des Repräsentanten als das Dokument

$$\left\{ \begin{array}{l} "r_i" : \left\{ \begin{array}{l} "timestep" : k_0, \\ "existence" : 0.9, \\ "color" : [0, 0.2, 0.4, 0.25, 0.15, 0], \\ "length" : \{ "μ" : 0.2, "σ" : 0.01, "Einheit" : "Meter" \}, \\ "type" : \left\{ \begin{array}{l} "Gabel" : 0.985, \\ "Löffel" : 0.012, \\ "Messer" : 0.003 \end{array} \right\} \end{array} \right\} \end{array} \right\},$$

in welchem die Werte aller deskriptiven Attribute sowie des Existenz- und Typattributs persistiert sind. Für die Wertebereiche von qualitativen Attributen wird dabei eine festgelegte Ordnung der Symbole angenommen. Das Typattribut wird dagegen als eine Liste von Werten dargestellt.

Beispiel 10 (Optimierte Speicherung als JSON im Zeitschritt $k_0 + \tau$).

Sei im Zeitschritt $k_0 + \tau$ derselbe Repräsentant r_i mit geänderten Werten seines Existenz-Attributs und seiner Typzuordnung gegeben. Der geänderte Repräsentant lässt sich dann in komprimierter Darstellung als reine Änderung gegenüber dem Basiszeitschritt k_0 in JSON darstellen als

$$\left\{ \begin{array}{l} "r_i" : \left\{ \begin{array}{l} "timestep" : k_0 + \tau, \\ "existence" : 0.875, \\ "type" : \left\{ \begin{array}{l} "Gabel" : 0.99, \\ "Löffel" : 0.01 \end{array} \right\} \end{array} \right\} \end{array} \right\}.$$

Unveränderte Attribute müssen somit nicht erneut gespeichert werden.

5.5 Weiterführende Aspekte der Informationsverwaltung

In diesem Kapitel wurden grundlegende Verfahren der probabilistischen Informationsverwaltung in der objektorientierten Umweltmodellierung dargestellt. Nicht detailliert eingegangen wurde auf den Aspekt der Zuordnung von Repräsentanten zu Konzepten des Hintergrundwissens. Dieser Aspekt wird nachfolgend in Kapitel 6 betrachtet.

Weiterführende Aspekte der Informationsverwaltung im objektorientierten Umweltmodell werden in den Arbeiten von Belkin [Bel17] beschrieben. Dies betrifft z. B. die Erkennung von Situationen in der beobachteten Umgebung auf Basis des repräsentierten Umgebungszustandes [Bel12a]. Dabei wird u. a. mittels einer quantitativen Analyse bewertet, ob die im Weltmodell vorliegenden Informationen ausreichend spezifisch bzgl. einer Situation sind. Dazu wird ein sog. Bestimmtheitswert berechnet. Dieser kann verwendet werden, um den aktiven Erwerb zusätzlicher Informationen in Bezug auf die betrachtete Situation auszulösen.

5.6 Zusammenfassung

In diesem Kapitel wurde die Verwaltung von erworbenen Umgebungsinformationen in der objektorientierten Umweltmodellierung vorgestellt. Einen wichtigen Anteil nimmt dabei die probabilistische Informationsverarbeitung des Weltmodells ein. Auch für die adaptive Umweltmodellierung stellt diese Informationsverarbeitung eine wichtige Grundlage dar. Daher wurden in diesem Kapitel die wichtigsten Ansätze aus Vorarbeiten zum objektorientierten Umweltmodell bzgl. der probabilistischen Informationsverarbeitung dargestellt. Diese betreffen u. a. die Datenassoziation, die Erzeugung und Aktualisierung von Repräsentanten sowie Qualitätsprüfungen. Als Beiträge dieser Arbeit zur probabilistischen Informationsverarbeitung wurden diese existierenden Ansätze dabei an einigen Stellen ergänzt und erweitert. Dies

betrifft z. B. die Datenassoziation sowie die Erzeugung neuer Repräsentanten. Weiterhin wurden in diesem Kapitel als Beiträge der Arbeit Themen auf konzeptioneller Ebene betrachtet. Dies betrifft die Verwaltung von probabilistischen Relationen, einen erweiterten zeitlichen Ablauf für die Informationsverwaltung sowie das Speichern und Verwenden von Erfahrungswerten in der Umweltmodellierung.

Auch wurde in diesem Kapitel eine formale Notation zur Beschreibung des objektorientierten Umweltmodells und seiner Inhalte festgelegt. Diese Notation wird in den nachfolgenden Kapiteln fortgeführt und erweitert, z. B. in Bezug auf die Repräsentant-zu-Konzept Zuordnung.

6 Bayes'sche Repräsentant-zu-Konzept Zuordnung

In diesem Kapitel wird die Zuordnung von Repräsentanten zu Konzepten behandelt. Diese Zuordnung spielt sowohl in der Informationsverwaltung als auch in der in den Kapiteln 7 und 8 beschriebenen adaptiven Umweltmodellierung eine wichtige Rolle. Die Repräsentant-zu-Konzept Zuordnung wird in Abschnitt 6.1 zunächst allgemein vorgestellt, zusammen mit der Darstellung eines existierenden Ansatzes in Abschnitt 6.1.2. Die Abschnitte 6.2 und 6.3 beschreiben dann den Beitrag dieser Arbeit, welcher aus einem alternativen Ansatz der Zuordnung mit gewissen, für den Einsatz in der adaptiven Umweltmodellierung wünschenswerten Eigenschaften besteht. In Abschnitt 6.4 wird als ein weiterer Beitrag dieser Arbeit eine Erweiterung des alternativen Ansatzes vorgestellt. Abschnitt 6.5 fasst das Kapitel schließlich zusammen.

6.1 Einführung und Motivation

In der objektorientierten Umweltmodellierung stellt das Hintergrundwissensmodell semantisches Vorwissen bezüglich relevanter Typen von Entitäten bereit. Unter Verwendung dieses Vorwissens kann der beobachtete Umgebungszustand des Weltmodells um Informationen ergänzt werden, welche nicht über die genutzten Sensoren bereitgestellt werden können. Repräsentanten im Weltmodell, welche eine Entität eines Typs darstellen, für den im Hintergrundwissen ein entsprechendes Konzept enthalten ist, können so

um die zusätzlich im Konzept modellierten Informationen ergänzt werden [Bel12b].

Die Voraussetzung für das Ergänzen derartiger semantischer Informationen ist die erfolgreiche Zuordnung eines Repräsentanten zu einem Konzept im Hintergrundwissen. Diese Aufgabe entspricht einer Klassifikation des Repräsentanten. Als Ziele dieser Klassifikation dienen die modellierten Konzepte des Hintergrundwissens bzw. eine geeignete Teilmenge davon. In der objektorientierten Umweltmodellierung erfolgt diese Klassifikation als Teil der schritthaltend durchgeführten Informationsverwaltung (vgl. Abschnitt 5.3.5) und wird als Repräsentant-zu-Konzept Zuordnung bezeichnet.

6.1.1 Die Repräsentant-zu-Konzept Zuordnung als Klassifikationsaufgabe

Im Allgemeinen kann Klassifikation als das Problem des Einlernens einer Funktion $y = h(x)$ beschrieben werden, welche für ein gegebenes Datum x als Funktionswert dessen Klasse y zurückgibt [Rus10]. Der Wertebereich der Funktion $h(\cdot)$ ist dabei diskret und entspricht den möglichen Klassen, welchen das Datum x angehören kann. Die Funktion $h(\cdot)$ wird dabei als Hypothese bezeichnet [Rus10] und kann gelernt werden. Im Fall eines überwachten Einlernens werden dazu Trainingsdaten benötigt, d. h. eine Menge von Wertepaaren (y_i, x_i) mit $i = 1, \dots, l$, welche die Funktion beispielhaft beschreiben. Da bei solchen Lernvorgängen vom Speziellen (Beispielhaften) auf das Allgemeine (Modellhafte) geschlossen wird, handelt es sich um eine Form der induktiven Inferenz. Besteht zwischen den Daten x_i und ihren Klassen y_i kein streng deterministischer, sondern ein probabilistischer Zusammenhang, so wird anstelle der Funktion $h(\cdot)$ als Modell eine bedingte Wahrscheinlichkeitsverteilung $p(y|x)$ gelernt.

Verfahren, welche zur Klassifikation im Bereich des überwachten Lernens eingesetzt werden können, sind z. B. Entscheidungsbäume und ihre Erweiterungen sowie Support-Vektor-Maschinen (SVM). Bei diesen Verfahren können die Daten x_i vektorwertige Merkmale darstellen. Weiterhin können auch künstliche neuronale Netze zur Klassifikation eingesetzt werden. In

deren Fall stellen die Eingabedaten meist Rohdaten dar, welche ohne eine vorhergehende Merkmalsextraktion genutzt werden, wie z. B. Bilddaten. Entsprechende Merkmale werden dann beim Training eines neuronalen Netzes mit eingelernt.

In der Praxis werden zur Klassifikation von Objekten in verschiedene Klassen oftmals binäre Klassifikationsverfahren eingesetzt. Diese Verfahren geben z. B. den Wert 1 aus, wenn ein gegebenes Objekt zur betrachteten Klasse gehört, und anderenfalls den Wert 0. Mehrere trainierte binäre Klassifikatoren können kombiniert werden, um eine Unterscheidung von mehr als zwei Klassen zu ermöglichen, im Falle eines sog. Multiklassen-Problems. Die gelernte Hypothese $h(\cdot)$ eines binären Klassifikators kann als ein Modell für die betrachtete Objektklasse verstanden werden.

Hierarchische Klassifikation

In der objektorientierten Umweltmodellierung sind die modellierten Konzepte hierarchisch in einer „is-a“-Generalisierungshierarchie angeordnet. Die Repräsentant-zu-Konzept Zuordnung stellt somit formal eine hierarchische Klassifikation dar. Die hierarchische Klassifikation kann als eine Erweiterung der allgemeinen Klassifikation verstanden werden. Hierarchische Klassifikationsprobleme können dabei nach Silla und Freitas [Sil11, Bor13] anhand von drei Kriterien unterschieden werden. Das erste Kriterium betrifft die der Hierarchie zugrunde liegende Struktur. Diese kann entweder in Form eines Baums gegeben sein oder allgemeiner als ein gerichteter azyklischer Graph (DAG¹). Das zweite Kriterium betrifft die Frage, ob ein Objekt gleichzeitig mehr als einer Klasse zugeordnet werden kann (sog. Multi-Label-Probleme). Das dritte Kriterium betrifft schließlich die Frage, ob als Ergebnis einer Klassifikation immer nur Blattknoten der Hierarchie genutzt werden können oder ob auch intermediäre Knoten als Klassen zulässig sind. Auf ähnliche Weise lassen sich auch die Verfahren, die zur Lösung dieser hierarchischen Klassifikationsprobleme eingesetzt

¹ Englisch: directed acyclic graph

werden, einordnen. Dabei werden zunächst dieselben drei Kriterien verwendet wie zur Beschreibung der Probleme. Als viertes Kriterium wird für Verfahren zusätzlich noch unterschieden, ob es sich beim Klassifikationsverfahren um ein flaches, lokales oder globales Verfahren handelt [Bor13]. Ein flaches Verfahren ignoriert dabei die hierarchischen Zusammenhänge zwischen den Klassen und betrachtet nur die Teilmenge der Blattknoten als Klassen. Als flache Verfahren können Standardverfahren zur Klassifikation wie z. B. SVMs eingesetzt werden. Lokale Verfahren setzen ebenfalls auf Standardverfahren auf und nutzen diese für eine von der Wurzel der Hierarchie ausgehende Top-Down-Klassifikation. Dabei kann z. B. für jeden Knoten der Hierarchie ein binärer Klassifikator trainiert werden oder pro Ebene der Hierarchie ein Multiklassen-Klassifikator. Im Allgemeinen wird als Ergebnis dieses Top-Down-Vorgehens ein Blattknoten als Klasse ausgewählt. Globale Verfahren verwenden dagegen nur einen Klassifikator über der ganzen Hierarchie und ermöglichen auch intermediäre Knoten als Ergebnis. Globale Verfahren sind dabei meist komplexer als flache oder lokale Verfahren [Bor13].

Besonderheiten der Repräsentant-zu-Konzept Zuordnung

Die Zuordnung von Repräsentanten zu Konzepten in der objektorientierten Umweltmodellierung stellt eine spezielle Art der Klassifikation dar. Zur Beschreibung der möglichen Klassen dient hierbei eine Menge $\mathcal{C} \subseteq \mathcal{C}_0$ von im Hintergrundwissen definierten Konzepten. Diese Konzepte sind dabei, wie bereits erwähnt, hierarchisch angeordnet. Die zu klassifizierenden Daten stellen die Repräsentanten $r \in \mathcal{R}$ des Weltmodells dar. Dabei werden sowohl die zu klassifizierenden Objekte, d. h. die Repräsentanten, als auch die Klassen, d. h. die Konzepte, nicht über deterministische Merkmale sondern probabilistisch beschrieben. Zur probabilistischen Beschreibung dienen die Attribute der Umweltmodellierung. Als weitere Besonderheit wird als Ergebnis formal nicht ein einzelnes Konzept gewünscht, sondern eine diskrete Wahrscheinlichkeitsverteilung über der Menge der betrachteten Konzepte.

Als Wertebereich der Repräsentant-zu-Konzept Zuordnung wird allgemein eine Teilmenge \mathcal{C} der im Hintergrundwissen \mathcal{C}_0 modellierten Konzepte genutzt. Je nach Ansatz kann diese Teilmenge alle Konzepte des Hintergrundwissens enthalten oder eine echte Teilmenge sein. Die Repräsentanten im Weltmodell werden für eine Zuordnung zu Konzepten über ihre Attribute beschrieben. Dabei spielen nur die deskriptiven Attribute eine Rolle, d. h. alle perzeptiven Attribute, jedoch nicht Existenz- oder Typ-Attribut. Genauer gesagt betrifft dies nur diejenigen deskriptiven Attribute, welche nicht rein zustandsbezogen sind. Das Ergebnis einer Zuordnung wird dann im Typ-Attribut eines Repräsentanten gespeichert. Das Existenz-Attribut besitzt zunächst keine Relevanz für die Zuordnung.

Notation

Für die formale Beschreibung der Repräsentant-zu-Konzept Zuordnung und auch die in nachfolgenden Kapiteln beschriebenen Anteile der adaptiven Umweltmodellierung wird die in Kapitel 5 eingeführte Notation erweitert. Ein Repräsentant $r \in \mathcal{R}$ wird dabei über seine deskriptiven Attribute $a^{r,i}$ für $i = 1, \dots, n$ beschrieben. Dies kann entweder in Form der Menge

$$\mathcal{A}_r := \{a^{r,1}, a^{r,2}, \dots, a^{r,n}\} \quad (6.1)$$

seiner Attribute erfolgen oder geordnet als der in Kapitel 5 eingeführte Vektor \underline{a}^r . Ein Konzept wird analog z. B. als die Menge

$$\mathcal{A}_c := \{a^{c,1}, a^{c,2}, \dots, a^{c,m}\} \quad (6.2)$$

seiner Attribute $a^{c,j}$ für $j = 1, \dots, m$ beschrieben. Dabei werden für Konzepte in \mathcal{A}_c ebenfalls nur diejenigen Attribute betrachtet, welche zu den deskriptiven Attributen der Repräsentanten korrespondieren. Die Korrespondenz besteht darin, dass durch die Attribute dieselben Qualitäten repräsentiert werden. Das Ergebnis einer Repräsentant-zu-Konzept Zuordnung wird im Sinne einer probabilistischen Klassifikation als die bedingte Wahrscheinlichkeit $p(c|r)$ für einen Repräsentanten r und ein Konzept c dargestellt.

6.1.2 Vorarbeiten zur Repräsentant-zu-Konzept Zuordnung

Ein Ansatz zur Repräsentant-zu-Konzept Zuordnung in der objektorientierten Umweltmodellierung wird von Belkin [Bel17, Bel12b] beschrieben. In diesem Ansatz werden alle Konzepte der „is-a“-Hierarchie eines Hintergrundwissensmodells betrachtet. Im Allgemeinen betrifft dies in Domänenmodellen alle modellierten Konzepte (jedoch nicht alle Relationen), d. h. es gilt: $\mathcal{C} = \mathcal{C}_0$. Die Klassifikation erfolgt in diesem Ansatz hierarchisch auf Basis der „is-a“-Beziehungen der Konzepte.

Vorgehen

Für einen gegebenen Repräsentanten wird dabei eine Tiefensuche nach passenden Konzepten in der „is-a“-Hierarchie durchgeführt. Ein Konzept gilt als passend, wenn bei einer Ähnlichkeitsbewertung ein definierter Schwellwert überschritten wird. Gilt dies für mehrere Konzepte in einem Zweig der Hierarchie, so wird das spezifischste Konzept des Zweiges gewählt. Dies ist das Konzept, welches am weitesten vom Wurzelknoten der „is-a“-Hierarchie entfernt ist. Die Ähnlichkeitsbewertung zwischen Repräsentant und einem betrachteten Konzept erfolgt zweistufig. In der ersten Stufe wird die strukturelle Ähnlichkeit bewertet. Dabei wird betrachtet, wie viele der für das Konzept definierten Attribute tatsächlich beobachtet wurden, also im Repräsentanten enthalten sind. Zu diesem Zweck werden die jeweiligen Attributmengen von Repräsentant und Konzept über die Jaccard-Metrik¹ verglichen. Die Jaccard-Metrik setzt dabei die Anzahl der gemeinsamen Attribute von Repräsentant und Konzept in Bezug zur (vereinigten) Gesamtanzahl der Attribute. In der zweiten Stufe werden die Wahrscheinlichkeitsverteilungen der gemeinsamen Attribute betrachtet und verglichen. Für diesen Vergleich wird die Kullback-Leibler-Divergenz genutzt. Zur Bewertung der Ähnlichkeit des Attributs eines Repräsentanten gegenüber dem korrespondierenden

¹ In [Bel12a] wird diese als Tanimoto Distanz bezeichnet.

Konzept-Attribut werden deren Verteilungen mittels der Kullback-Leibler-Divergenz verglichen. Diese Bewertungen pro Attribut werden dann als eine gewichtete Summe zu einer Gesamtbewertung kombiniert, welche das Ergebnis der zweiten Stufe darstellt. Schließlich müssen die Ergebnisse aus der ersten Stufe, dem strukturellen Vergleich, und aus der zweiten Stufe, dem Vergleich der probabilistischen Attribute, noch zum Gesamtergebnis kombiniert werden. Dies erfolgt ebenfalls in Form einer gewichteten Summe. Zuvor werden die beiden Einzelergebnisse jedoch normiert, d. h. auf das Intervall $[0,1]$ abgebildet. Weiterhin kann unter Anwendung des Satzes von Bayes eine A-priori-Wahrscheinlichkeit für die betrachteten Konzepte in die Zuordnung mit einfließen. Für einen Repräsentanten r und ein betrachtetes Konzept c ergibt sich nach [Bel17] eine Zuordnung $p(c|r)$ somit als die bedingte Wahrscheinlichkeit

$$\begin{aligned} p(c|r) &\sim p(r|c) \cdot p(c) \\ &= \left(w_s \cdot f_s(d_s(r, c)) + w_v \cdot f_v(d_v(r, c)) \right) \cdot p(c) . \end{aligned} \quad (6.3)$$

Der Index s bezeichnet dabei den strukturellen Vergleich, wohingegen der Index v den Vergleich der probabilistischen Attribute beschreibt. Die Gewichtung ist durch w_s bzw. w_v gegeben. Weiterhin beschreiben die Funktionen $d_s(\cdot)$ und $d_v(\cdot)$ die genannten Distanzmaße. Die Funktionen $f_s(\cdot)$ und $f_v(\cdot)$ dienen der Normierung dieser Distanzmaße.

Eigenschaften des Ansatzes

Der Ansatz nach [Bel17] zeichnet sich durch einige Besonderheiten aus. Zunächst betrachtet der Ansatz explizit ein hierarchisches Wissensmodell und führt auf diesem eine hierarchische Klassifikation durch. Nach den in [Sil11] definierten Kriterien stellt der Ansatz dabei ein Verfahren dar, welches

- auf einem gerichteten azyklischen Graphen als Struktur der Hierarchie angewendet werden kann,

- nicht nur Blattknoten als Ergebnisklassen ausgeben kann, sondern auch intermediäre Knoten,
- als Ergebnis Knoten auf mehr als einem Zweig ausgeben kann und
- insgesamt ein globales Klassifikationsverfahren darstellt.

Bei hierarchischen Verfahren können wie beschrieben entweder nur Blattknoten als Ergebnisse ausgegeben werden oder auch intermediäre Knoten. Sind auch intermediäre Knoten zulässig und stellt die betrachtete Hierarchie eine „is-a“ Generalisierungsbeziehung dar, so kann es eine Anforderung sein, pro Zweig der Hierarchie nur einen Knoten als Ergebnis auszuwählen. Eine solche Anforderung ist auch im Falle der Repräsentant-zu-Konzept Zuordnung in der objektorientierten Umweltmodellierung vorteilhaft.

Betroffen ist von diesem Aspekt z. B. das Ableiten von semantischen Informationen aus Konzepten. Dieses Ableiten erfolgt anteilig anhand der probabilistischen Zuordnung von Repräsentanten zu Konzepten. Wäre hier neben einem Konzept auch sein Vaterkonzept in einer Zuordnung anteilig enthalten, so könnte dies zu einer ungewollten Verzerrung der abgeleiteten Anteile führen. Dies liegt darin begründet, dass die probabilistischen Attributwerte eines Konzepts und seines Vaterkonzepts i. A. Abhängigkeiten besitzen. Eine solche Verzerrung kann wiederum zu Problemen bei einer nachgelagerten Weiterverarbeitung der durch Repräsentanten dargestellten Informationen führen. Der bisherige Ansatz des Umweltmodells [Bel17] wählt daher pro Zweig aus den möglichen Konzepten immer nur dasjenige Konzept aus, welches am weitesten von der Wurzel entfernt ist. Die möglichen Konzepte sind dabei alle Konzepte, deren nach Gleichung (6.3) berechnete Ähnlichkeit einen definierten Schwellwert überschreitet.

Eine weitere wichtige Eigenschaft des Ansatzes [Bel17] ist es, als Ergebnis eine Wahrscheinlichkeitsverteilung zu liefern, definiert über der Menge der möglichen, d. h. hinreichend ähnlichen Konzepte. Somit kann der Ansatz

auch als ein Multi-Label-Verfahren betrachtet werden, welches zu einem Repräsentanten mehrere mögliche Konzepte ausgibt. Weiterhin sieht der Ansatz vor, dass auf jeder Ebene der Hierarchie eine sog. Dummy-Klasse genutzt werden kann, welche stellvertretend für bisher nicht modellierte Konzepte steht. Diese Dummy-Klasse kann in der Klassifikation als eine Rückweisungsklasse fungieren.

Nicht unterschieden werden in [Bel17] die verschiedenen Szenarmodi für Attribute. Damit unterscheidet sich der Ansatz auf eine wesentliche Weise von den im Metamodell und in dieser Arbeit getroffenen Annahmen. In dieser Arbeit wird davon ausgegangen, dass mit einer gegebenen Konfiguration von Sensoren in einem kognitiven System auch die beobachtbaren Eigenschaften von Objekten festgelegt werden. Somit bestimmt bereits die Systemkonfiguration, welche Qualitäten als perceptiv gelten. Eine Konsequenz daraus ist die Annahme, dass für alle beobachteten Objekte i. A. die gleichen Qualitäten beobachtet und als Attribute von Repräsentanten im Weltmodell dargestellt werden. Zugleich wird davon ausgegangen, dass deduktive und semantische Attribute nicht direkt durch Beobachtung der Umgebung bestimmt werden können. Dies hat zur Folge, dass der strukturelle Vergleich von Repräsentanten zu Konzepten in der ersten Stufe des Ansatzes in [Bel12a] unter den Annahmen in dieser Arbeit keine Aussagekraft bezüglich der Unterscheidung von Konzepten besitzt. Darüber hinaus sind im in dieser Arbeit verfolgten Ansatz sogar nur diejenigen perceptiven Attribute für eine Zuordnung aussagekräftig, die keine zustandsbezogenen Qualitäten beschreiben. Der Ansatz in [Bel17] unterliegt dagegen anderen Annahmen. Beispielsweise werden hier für Repräsentanten auch Attribute genutzt, die beziehungsbezogene Informationen darstellen, z. B. welche Teile ein Objekt besitzt. Werden solche Attribute verwendet, kann ein struktureller Vergleich zu einer Unterscheidung von Konzepten beitragen. Im in dieser Arbeit verfolgten Ansatz werden derartige Information dagegen mittels Relationen dargestellt.

6.1.3 Motivation eines Bayes'schen Ansatzes für die Repräsentant-zu-Konzept Zuordnung

Eine Repräsentant-zu-Konzept Zuordnung ist eine wichtige Voraussetzung für die adaptive Umweltmodellierung, z. B. in Bezug auf die quantitative Modellbewertung oder das Auffinden von Repräsentanten, welche nur schlecht von einem Hintergrundwissensmodell beschrieben werden. Für die adaptive Umweltmodellierung wird dabei eine Variante der Repräsentant-zu-Konzept Zuordnung benötigt, welche sich direkt in deren Verfahren integrieren lässt und auf der Bayes'schen Schätztheorie aufsetzt. Der existierende Ansatz von Belkin [Bel17] ist für diese Zwecke nicht geeignet, auch wegen der zuvor beschriebenen unterschiedlichen Modellierungsannahmen.

Für die adaptive Umweltmodellierung ist weiterhin eine einfache Variante der Repräsentant-zu-Konzept Zuordnung ausreichend, welche ein flaches Klassifikationsverfahren umsetzt. Dabei wird das Hintergrundwissensmodell \mathcal{C}_0 vereinfachend rein als eine Menge von Konzepten betrachtet, genauer gesagt als eine Teilmenge \mathcal{C} . Diese Teilmenge kann beispielsweise, wie in Abschnitt 4.5.2 beschrieben, aus den probabilistisch modellierten Blattknoten der „is-a“-Generalisierungshierarchie bestehen.

In dieser Arbeit wurde aus dargelegten Gründen eine eigene Variante der Repräsentant-zu-Konzept Zuordnung entwickelt und in [Kuw13b, Kuw16] vorgestellt. Diese Variante weist die oben beschriebenen Eigenschaften auf und besitzt weiterhin den Vorteil, eine geschlossene Berechnung der Zuordnungswahrscheinlichkeiten zu ermöglichen. Die Variante basiert dabei auf der Idee, die Attribute eines Repräsentanten einzeln mit den Attributen eines betrachteten Konzepts zu vergleichen. Der Vergleich soll dabei bewerten, wie sehr die in der Verteilung eines Repräsentanten-Attributs enthaltenen Werte auch in der Verteilung des modellierten Konzept-Attributs enthalten sind. Je mehr dies der Fall ist, so die Anschauung, desto eher gehört der Repräsentant zum betrachteten Konzept (basierend auf der Betrachtung eines einzelnen Attributs). Somit lässt sich zunächst pro Attribut eine anteilige Repräsentant-zu-Konzept Zuordnung berechnen. Diese kann in Form einer

bedingten Wahrscheinlichkeitsverteilung dargestellt werden. Die derart berechneten Anteile können anschließend probabilistisch zu einer vollständigen Repräsentant-zu-Konzept Zuordnung kombiniert werden.

Nachfolgend wird in Abschnitt 6.2 zunächst die Herleitung der anteiligen Repräsentant-zu-Konzept Zuordnungen pro Attribut und deren Kombination beschrieben, wie in [Kuw13b] präsentiert. In Abschnitt 6.3 wird dann die Umsetzung des Ansatzes beschrieben und demonstriert. Anschließend werden in Abschnitt 6.4 mögliche Erweiterungen und Verbesserungen dieses Ansatzes diskutiert, wie in [Kuw16] vorgestellt.

6.2 Herleitung

Der in dieser Arbeit entwickelte alternative Ansatz zur Repräsentant-zu-Konzept Zuordnung basiert auf einer Betrachtung, in welcher Repräsentanten mit der gemeinsamen Wahrscheinlichkeitsverteilung ihrer probabilistischen Attribute gleichgesetzt werden. Unter der Annahme von stochastischer Unabhängigkeit wird die Zuordnung dann zunächst individuell pro Attribut berechnet. Dazu werden die probabilistisch beschriebenen Attribute $a^{r,i} \in \mathcal{A}_r$ eines Repräsentanten r mit denen eines betrachteten Konzepts verglichen. Als Ergebnis dieses Vergleichs ergibt sich die bedingte Wahrscheinlichkeitsverteilung $p(c | a^{r,i})$ über den Konzepten $c \in \mathcal{C}$. Diese Wahrscheinlichkeitsverteilung, welche eine anteilige Repräsentant-zu-Konzept Zuordnung repräsentiert, wird nachfolgend als attributbasierte Zuordnungswahrscheinlichkeit bezeichnet.

Die beobachteten Attribute sind bei diesem Vorgehen wie erwähnt i. A. perzeptive, nicht zustandsbezogene Attribute. Falls es angebracht ist, können allerdings auch deduktive Attribute in die Berechnung der Zuordnung mit aufgenommen werden. Die im Folgenden vorgestellte Methodik ist agnostisch für die szenarbezogene Rolle und Bedeutung von Attributen. Eine Verwendung semantischer Attribute ist allerdings widersinnig.

Attributbasierte Zuordnungswahrscheinlichkeiten betrachten jedes Attribut für sich. Um insgesamt die Zuordnungswahrscheinlichkeit eines Repräsentanten r zu einem gegebenen Konzept c berechnen zu können, müssen die einzelnen attributbasierten Wahrscheinlichkeiten kombiniert werden. Im nächsten Abschnitt wird zunächst auf die grundsätzliche Berechnung der attributbasierten Zuordnungswahrscheinlichkeiten eingegangen. Deren Kombination zum Gesamtergebnis der Repräsentant-zu-Konzept Zuordnung wird anschließend in Abschnitt 6.2.2 beschrieben.

6.2.1 Attributbasierte Zuordnungswahrscheinlichkeiten

Zur Berechnung der attributbasierten Zuordnungswahrscheinlichkeiten $p(c | a^{r,i})$ wird ein Ansatz aus der Bayes'schen Schätztheorie verwendet. Einführend soll zunächst die folgende Problemstellung betrachtet werden.

Rückwärtsinferenz

Sei eine diskrete Zufallsvariable \mathbf{c} gegeben sowie eine weitere Zufallsvariable \mathbf{r} . Gesucht wird die Wahrscheinlichkeitsverteilung der Zufallsvariablen \mathbf{c} , wenn die Zufallsvariable \mathbf{r} bekannt ist, also die bedingte Wahrscheinlichkeitsverteilung $p(\mathbf{c} | \mathbf{r})$. Dazu sei weiterhin ein probabilistischer Zusammenhang zwischen den beiden Zufallsvariablen gegeben, beschrieben über die bedingte Wahrscheinlichkeitsverteilung $p(\mathbf{r} | \mathbf{c})$, welche \mathbf{c} zu \mathbf{r} in Beziehung setzt. Würde für \mathbf{r} nun ein (deterministischer) Wert beobachtet werden, d. h. eine Realisierung \hat{r} , so kann unter Anwendung des Satzes von Bayes die gesuchte bedingte Wahrscheinlichkeit als

$$p(\mathbf{c} | \hat{r}) = \frac{1}{z} \cdot p(\hat{r} | \mathbf{c}) \cdot p(\mathbf{c}) \quad (6.4)$$

berechnet werden. Der Term z stellt hierbei einen Normierungsfaktor dar und $p(\mathbf{c})$ beschreibt die A-priori-Verteilung der Zufallsvariablen \mathbf{c} . Dieses Vorgehen stellt eine sog. Rückwärtsinferenz dar [Sch11], da von \mathbf{r} auf \mathbf{c} geschlossen wird, wohingegen der Zusammenhang der Zufallsvariablen in

Richtung von \mathbf{c} zu \mathbf{r} modelliert wurde. Eine Rückwärtsinferenz wird z. B. auch in der Datenassoziation (vgl. Abschnitt 5.2.1) verwendet, um auf Basis eines Beobachtungsmodells und einer konkreten Beobachtung die deskriptiven Attribute eines Repräsentanten aktualisieren zu können.

Zuordnung als Rückwärtsinferenz

Die attributbasierten Zuordnungswahrscheinlichkeiten $p(c | a^{r,i})$ werden in dieser Arbeit nun so interpretiert, dass als Zufallsvariable \mathbf{c} ein Konzept $c \in \mathcal{C}$ betrachtet wird, gegeben der Wert für ein Attribut $a^{r,i}$ eines betrachteten Repräsentanten. Unter dieser Interpretation könnte nun die Rückwärtsinferenz in Gleichung (6.4) angewendet werden, um die Zuordnungswahrscheinlichkeit bzgl. $a^{r,i}$ zu bestimmen. Dabei muss nun aber beachtet werden, dass in der objektorientierten Umweltmodellierung Attribute nicht deterministisch über einen Wert \hat{a} beschrieben werden, sondern probabilistisch mittels einer DoB-Verteilungen $p(a)$. Für die betrachtete Rückwärtsinferenz führt dies zu der Problematik, dass mit $p(c | a^{r,i})$ eine Wahrscheinlichkeitsverteilung berechnet werden soll, welche formal auf eine andere Wahrscheinlichkeitsverteilung bedingt ist, nicht auf einen Wert. Dies ist nach Wahrscheinlichkeitstheorie nicht möglich [Sch11]. Um diese Problematik zu umgehen, wird in [Sch11] die Einführung einer sog. Dummy-Variablen vorgeschlagen.

Rückwärtsinferenz für unsichere Beobachtungen

Sei \mathbf{d} eine weitere Zufallsvariable, die Dummy-Variable. Zwischen den Zufallsvariablen \mathbf{d} und \mathbf{r} wird ebenfalls ein probabilistischer Zusammenhang angenommen. Dieser ergibt sich formal in Form der bedingten Wahrscheinlichkeit $p(r | d)$. Um nun formal korrekt beschreiben zu können, dass die Verteilung der Zufallsvariablen \mathbf{c} auf die Verteilung der Zufallsvariablen \mathbf{r} bedingt ist, wird die betrachtete Problemstellung in [Sch11] erweitert. Sei dazu $p(r)$ zusätzlich die bekannte Verteilung für \mathbf{r} (die Verteilung, auf welche \mathbf{c} bedingt werden soll). In der erweiterten Problemstellung [Sch11] wird anstelle von $p(c | \hat{r})$ nun die bedingte Wahrscheinlichkeitsverteilung $p(c | \hat{d})$

betrachtet, welche auf eine Beobachtung der Dummy-Variablen \hat{d} bedingt ist. Um diese Verteilung durch Rückwärtsinferenz bestimmen zu können, muss zunächst die bedingte Wahrscheinlichkeit $p(\hat{d} | r)$ bestimmt werden, welche vom Wert \hat{d} abhängt. Da \hat{d} keine echte Beobachtung darstellt, wird die Bestimmung dieser bedingten Wahrscheinlichkeit nur formal durchgeführt. Nach [Sch11] kann zu diesem Zweck die Annahme getroffen werden, dass die Beobachtung von \hat{d} zu einer Modifizierung der über r verfügbaren Informationen führt. Diese Modifizierung wird dabei über die Verteilung $p(r)$ beschrieben, wobei sich die formale Verteilung $p(r | \hat{d})$ dann als proportional zur bekannten Verteilung $p(r)$ ergibt [Sch11]. Mit dem Satz von Bayes ergibt sich dann auch die zunächst gesuchte Verteilung $p(\hat{d} | r)$ als $p(r)$.

Auf Basis dieses Ergebnisses kann nun die Rückwärtsinferenz von \hat{d} zu c durchgeführt werden [Sch11]. Dazu wird die gemeinsame Wahrscheinlichkeitsverteilung von c , r und \hat{d} betrachtet und anhand der vorliegenden probabilistischen Zusammenhänge faktorisiert. Hierbei ergibt sich auch $p(\hat{d} | r)$ als ein Faktor, für welchen nach obiger Annahme $p(r)$ eingesetzt werden kann. Insgesamt ergibt sich daraus dann die gesuchte bedingte Wahrscheinlichkeitsverteilung als

$$p(c | \hat{d}) = \frac{1}{z} \cdot p(c) \cdot \int_{\mathbb{R}} p(r) \cdot p(r | c) \, dr . \quad (6.5)$$

In dieser Gleichung stellt z wieder einen Normierungsfaktor dar und $p(c)$ ist wieder die A-priori-Verteilung der Zufallsvariablen c . Das erweiterte Vorgehen von [Sch11] unter Verwendung einer Dummy-Variablen wurde an dieser Stelle nur verkürzt dargestellt. Einzelheiten sind in [Sch11] gegeben.

Berechnung der attributbasierten Zuordnung

Zur Berechnung der attributbasierten Zuordnungswahrscheinlichkeiten kann nun Gleichung (6.5) verwendet werden. Wie zuvor wird dabei c in (6.5) als eine Zufallsvariable über der Menge der Konzepte \mathcal{C} interpretiert. Die Zufallsvariable r bezieht sich weiterhin auf ein beobachtetes Attribut

$a^{r,i}$ eines Repräsentanten r . Somit wird $p(r)$ als die Wahrscheinlichkeitsverteilung $p_{a^{r,i}}(a)$ des Attributs $a^{r,i}$ interpretiert. Unter dieser Interpretation beschreibt der probabilistische Zusammenhang zwischen \mathbf{c} und \mathbf{r} in Form der bedingten Wahrscheinlichkeitsverteilung $p(r|c)$ in (6.5) dann, wie die Werte eines Attributs a verteilt sind, wenn ein Konzept c gegeben ist. Dabei wird a als ein Attribut a^{c,j_i} des Konzepts c interpretiert, welches dieselbe Qualität beschreibt wie $a^{r,i}$, also das zu $a^{r,i}$ korrespondierende Konzept-Attribut darstellt. Die Verteilung $p(r|c)$ entspricht somit der im Konzept c modellierten DoB-Verteilung $p_{a^{c,j_i}}(a)$ für das Attribut a^{c,j_i} . Nachfolgend wird das korrespondierende Konzept-Attribut a^{c,j_i} abkürzend als $a^{c,i}$ dargestellt. Somit kann Gleichung (6.5) unter der beschriebenen Interpretation als

$$p(c|a^{r,i}) = \frac{1}{z} \cdot p(c) \cdot \int_{\mathbb{R}} p_{a^{r,i}}(a) \cdot p_{a^{c,i}}(a) da \quad (6.6)$$

zur Berechnung der attributbasierten Zuordnungswahrscheinlichkeit für ein Attribut $a^{r,i}$ genutzt werden.

Bei diesem Vorgehen zur Berechnung der anteiligen Zuordnungswahrscheinlichkeit wird der Vergleich eines Repräsentanten-Attributs mit dem korrespondierenden Konzept-Attribut durch eine Integration über dem Produkt ihrer Wahrscheinlichkeitsverteilungen beschrieben. Anschaulich kann dies so interpretiert werden, dass aus der Verteilung des Konzept-Attributs diejenige Wahrscheinlichkeitsmasse gewichtet ausgewählt wird, welche mit der Verteilung des Repräsentanten-Attributs überlappt.

6.2.2 Kombination der Anteile

Um die Zuordnungswahrscheinlichkeit $p(c|r)$ eines Repräsentanten r zu einem Konzept c insgesamt, d. h. über alle Attribute, beschreiben zu können, müssen die attributbasierten Zuordnungswahrscheinlichkeiten $p(c|a^{r,i})$ kombiniert werden. In der objektorientierten Umweltmodellierung werden die einzelnen Attribute von Repräsentanten bzw. von Konzepten als stochastisch unabhängig angenommen.

Iterative Kombination

Unter dieser Voraussetzung kann ein iteratives Vorgehen zur Kombination der attributbasierten Zuordnungswahrscheinlichkeiten definiert werden. In jedem Schritt eines solchen iterativen Vorgehens wird dabei angenommen, dass im Schritt zuvor bereits die anteiligen Zuordnungswahrscheinlichkeiten für die ersten $k - 1 < n$ Attribute eines Repräsentanten zu einer gemeinsamen Zuordnungswahrscheinlichkeit $p(c | a^{r,1}, a^{r,2}, \dots, a^{r,k-1})$ kombiniert wurden. Im aktuellen Schritt wird dann die anteilige Zuordnungswahrscheinlichkeit $p(c | a^{r,k})$ in die bisherige gemeinsame Zuordnungswahrscheinlichkeit integriert, um eine neue gemeinsame Zuordnungswahrscheinlichkeit $p(c | a^{r,1}, a^{r,2}, \dots, a^{r,k})$ zu erhalten. Die Integration erfolgt, indem in Gleichung (6.6) für die priore Verteilung $p(c)$ die bisherige gemeinsame Zuordnungswahrscheinlichkeit $p(c | a^{r,1}, a^{r,2}, \dots, a^{r,k-1})$ des vorherigen Schritts angenommen wird. Im ersten Schritt wird als priore Verteilung initial eine Gleichverteilung über den Konzepten $c \in \mathcal{C}$ angenommen.

Unter Anwendung dieses iterativen Vorgehens können die attributbasierten Zuordnungswahrscheinlichkeiten $p(c | a^{r,i})$ für $i = 1, \dots, n$ nun zur Repräsentant-zu-Konzept Zuordnung $p(c | r) = p(c | a^{r,1}, a^{r,2}, \dots, a^{r,n})$ kombiniert werden. Somit ergibt sich der in dieser Arbeit entwickelte alternative Ansatz zur Repräsentant-zu-Konzept Zuordnung insgesamt als

$$p(c|r) = \frac{1}{Z} \cdot p(c) \cdot \prod_{a^{r,i} \in \mathcal{A}_r} \left(\int_{\mathbb{R}} p_{a^{r,i}}(a) \cdot p_{ac,i}(a) \, da \right) \cdot (6.7)$$

Das Produkt in Gleichung (6.7) wird dabei über die in einem Anwendungsfall betrachteten deskriptiven Attribute der Repräsentanten gebildet. Wie bereits erwähnt, betrifft dies i. A. die perzeptiven, nicht zustandsbezogenen Attribute. Das Attribut $a^{c,i}$ im Integral stellt das zu einem Repräsentanten-Attribut $a^{r,i}$ korrespondierende Konzept-Attribut dar.

Gleichung (6.7) beschreibt die Zuordnung des Repräsentanten r zu einem der Konzepte $c \in \mathcal{C}$. Um auf Basis dieser Gleichung die Verteilung der Zuordnungswahrscheinlichkeit von r über allen Konzepten zu erhalten, müssen die pro Konzept erhaltenen Werte mittels des Faktors $\frac{1}{z}$ normiert werden. Ähnlich wie im in [Bel17] beschriebenen Ansatz geht dieser Normierung hier ein einfacher Schwellwertvergleich voraus. Durch diesen Schwellwertvergleich wird vor allem der Fall behandelt, dass für einen Repräsentanten nur nicht zuordenbare Konzepte mit sehr kleinen Zuordnungswerten vorliegen. Eine einfache Normierung kann in diesem Fall dazu führen, dass durch die sich ergebende Verteilung auch nicht relevante Konzepte eine hohe Wahrscheinlichkeit zugesprochen bekommen. Dies wird an dieser Stelle durch einen einfachen Ansatz verhindert. Einer genaueren Betrachtung dieser Problematik widmet sich diese Arbeit in Abschnitt 6.4.

6.3 Umsetzung und erste Demonstration des Ansatzes

Der zuvor beschriebene Ansatz wird in dieser Arbeit zur Repräsentant-zu-Konzept Zuordnung verwendet. Für die Implementierung von Gleichung (6.7) müssen dabei diskrete von stetigen Attributen unterschieden werden. Für diskrete Attribute muss das Integral über dem Produkt der Verteilungen durch eine Summe ersetzt werden. Für stetige Attribute kann dieses Integral numerisch ausgewertet werden. Werden als stetige Wahrscheinlichkeitsverteilungen nur Normalverteilungen oder Gaußmischverteilungen genutzt, so kann auch eine analytische Auswertung erfolgen. Diese basiert im Kern auf der Berechnung des Produkts der Dichtefunktionen zweier normalverteilter Zufallsvariablen. Der Vorteil einer analytischen Auswertung ist neben der Umgehung von numerischen Instabilitäten auch die sehr schnelle Berechnung der Integralwerte.

6.3.1 Aufwandsbetrachtung und Berechnungsaspekte

Allgemein betrachtet muss die Repräsentant-zu-Konzept Zuordnung für jeden Repräsentanten $r \in \mathcal{R}$ berechnet werden. Dabei müssen pro Repräsentant alle Konzepte $c \in \mathcal{C}$ betrachtet werden. Zur Berechnung der Zuordnungswerte müssen alle relevanten Attribute $a^{r,i} \in \mathcal{A}_r$ des Repräsentanten r mit den Konzept-Attributen \mathcal{A}_c verglichen werden. Die Relevanz von Attributen für die Repräsentant-zu-Konzept Zuordnung ergibt sich über die durch die Attribute beschriebenen Qualitäten der repräsentierten Entitäten. Relevant sind dabei Attribute für Qualitäten, deren Werte diskriminativ in Bezug auf die Unterscheidung von Typen von Entitäten sind. Im Allgemeinen betrifft dies, wie zuvor bereits erwähnt, die perzeptiven, nicht zustandsbezogenen Attribute der Repräsentanten. Für diskrete Attribute muss dabei eine Summe über ihren Wertebereich berechnet werden. Für stetige Attribute mit Normalverteilung kann der Wert analytisch berechnet werden, für Attribute mit einer Gaußmischverteilung muss anschließend noch eine Summe über alle Komponenten berechnet werden. Der Berechnungsaufwand der Repräsentant-zu-Konzept Zuordnung ist somit linear in der Anzahl der Repräsentanten und Konzepte sowie in der Anzahl der zu ihrer Beschreibung verwendeten Attribute und der Größe der Wertebereiche dieser Attribute. Somit ergibt sich insgesamt eine Zeitkomplexität von $O(|\mathcal{R}| \cdot |\mathcal{C}| \cdot |\mathcal{A}_r^*| \cdot |S_a^*|)$, wobei $|\mathcal{A}_r^*|$ die maximale Anzahl von Attributen pro Repräsentant beschreibt. Der Faktor $|S_a^*|$ beschreibt das Maximum über den größten Wertebereich der diskreten Attribute und die größte Anzahl von Komponenten in Gaußmischverteilungen der stetigen Attribute.

Je nachdem, wie häufig die Zuordnung zwischen Repräsentanten und Konzepten bestimmt werden muss, kann die Berechnungsdauer der Zuordnung ins Gewicht fallen. Dies kann z. B. wichtig sein, wenn Echtzeitanforderungen an ein kognitives System bestehen. Im in Abschnitt 5.3.5 beschriebenen Verarbeitungsschema des objektorientierten Umweltmodells wird in jedem Zeitschritt die Zuordnung der Repräsentanten berechnet.

Eine Neuberechnung gegenüber einem bereits zuvor berechneten Wert muss allerdings nur für die im aktuellen Zeitschritt veränderten Repräsentanten

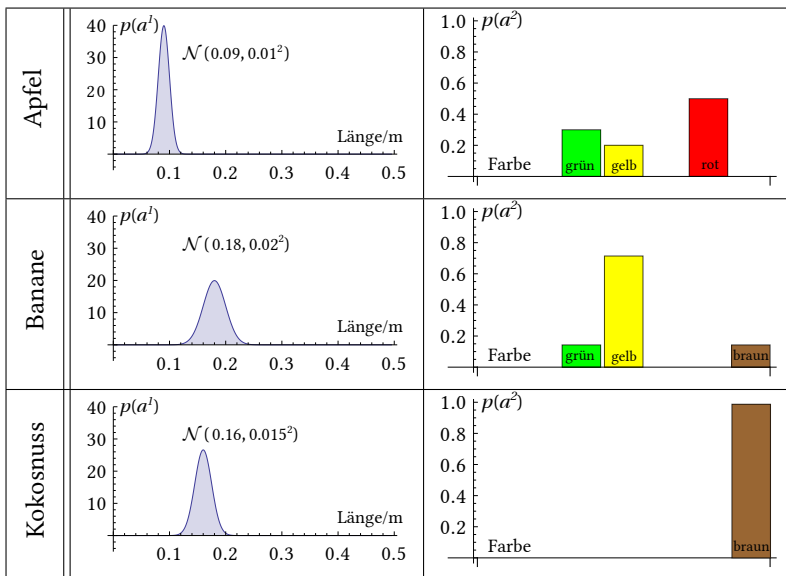
erfolgen. Veränderungen ergeben sich für Repräsentanten in einem Zeitschritt als Folge ihrer zeitlichen Fortschreibung und eventuellen Aktualisierung aufgrund einer Beobachtung. Für die Repräsentant-zu-Konzept Zuordnung sind dabei nur Änderungen an den der Zuordnung zugrunde gelegten Attributen eines Repräsentanten relevant. Welche Attribute dies betrifft, hängt auch von der Modellierung der Anwendungsdomäne ab. Eine einfache Ausgangslage kann dabei z. B. vorliegen, wenn eine zeitliche Fortschreibung nur für zustandsbezogene perzeptive Attribute erfolgt und die statischen Eigenschaften von Objekten, wie z. B. deren Abmessungen, keiner Alterung unterliegen (modelliert durch einen Alterungsfaktor von 1). In dieser Situation hat die zeitliche Fortschreibung der Repräsentanten keinen Einfluss auf die für die Repräsentant-zu-Konzept Zuordnung relevanten Attribute eines Repräsentanten. Relevante Änderungen an einem Repräsentanten ergeben sich dann nur aufgrund der Aktualisierung des Repräsentanten durch eine Beobachtung. Somit muss in dieser Situation auch nur für den bzw. die durch eine Beobachtung (anteilig) betroffenen und aktualisierten Repräsentanten eine Neuberechnung erfolgen. Ein solches Vorgehen kann, wenn aus Gründen der Laufzeiteffizienz gewünscht, auch unabhängig von der Domänenmodellierung erreicht werden. Dazu kann ein approximativer Verarbeitungsmodus für das objektorientierte Umweltmodell definiert werden, in welchem eine zeitliche Fortschreibung immer nur für die von einer Beobachtung betroffenen Repräsentanten erfolgt.

Eine Neuberechnung muss ebenfalls erfolgen, wenn sich die Definition eines betrachteten Konzepts ändert. Dies kann z. B. im Rahmen der adaptiven Umweltmodellierung der Fall sein. Wird hier die Definition eines Konzepts bzgl. seiner deskriptiven Attribute geändert, so muss eine Neuberechnung für alle Repräsentanten erfolgen. Dabei muss allerdings nur die Zuordnungswahrscheinlichkeit zwischen dem geänderten Konzept und jedem Repräsentanten neu berechnet werden, die Zuordnungswahrscheinlichkeiten von unveränderten Konzepten sind davon nicht betroffen.

6.3.2 Demonstrationsszenario

Zur Demonstration des Ansatzes wird ein einfaches Beispielszenario genutzt. Dieses Beispielszenario entstammt dem Bereich einer Haushaltsumgebung und wurde in [Kuw13b] vorgestellt. Für das einfache Demonstrationsszenario besteht die Menge \mathcal{C} der für die Zuordnung relevanten Konzepte aus nur drei Konzepten: $\mathcal{C} = \{\text{Apfel}, \text{Banane}, \text{Kokosnuss}\}$. Jedes Konzept wird beispielhaft über zwei Attribute beschrieben: ein diskretes Farbattribut und ein stetiges Längenattribut. Die Werte der Konzept-Attribute im Demonstrationsszenario sind in Tabelle 6.1 dargestellt.

Tabelle 6.1: Die Menge $\mathcal{C} = \{\text{Apfel}, \text{Banane}, \text{Kokosnuss}\}$ der Konzepte in einem einfachen Demonstrationsszenario aus der Haushaltsdomäne, beschrieben über ein stetiges Längenattribut und ein diskretes Farbattribut.



Weiterhin sind Repräsentanten definiert, welche beobachtete Objekte repräsentieren, darunter ein Apfel (*Apfel1*), eine Kokosnuss (*Kokosnuss1*) und eine Birne (*Birne1*). Die Attributwerte der definierten Repräsentanten sind in Tabelle 6.2 dargestellt. Die Länge wird dabei jeweils als Normalverteilung $\mathcal{N}(\mu, \sigma^2)$ beschrieben und ist in Zentimetern angegeben.

Tabelle 6.2: Beispielhafte Repräsentanten für ein einfaches Demonstrationsszenario mit zwei Attributen.

Name	Länge/cm	Farbe
<i>Apfel1</i>	$\mathcal{N}(8, 0.5^2)$	grün-gelb (1:1)
<i>Apfel2</i>	$\mathcal{N}(7, 0.2^2)$	rot
<i>Kokosnuss1</i>	$\mathcal{N}(15, 0.75^2)$	braun
<i>Birne1</i>	$\mathcal{N}(13, 0.2^2)$	grün-gelb (3:1)
<i>Erdbeere1</i>	$\mathcal{N}(3.5, 1^2)$	rot

6.3.3 Ergebnisse im Demonstrationsszenario

Die Ergebnisse der Repräsentant-zu-Konzept Zuordnung für die drei genannten Repräsentanten sind in Abbildung 6.1 dargestellt. Es ist erkennbar, dass der *Apfel1*-Repräsentant wie erwartet dem Konzept *Apfel* zugeordnet wird. Ebenso wird der Repräsentant *Kokosnuss1* dem Konzept *Kokosnuss* zugeordnet. Nur der Repräsentant *Birne1* kann keinem der Konzepte in \mathcal{C} eindeutig zugeordnet werden. Hier ergibt sich als Ergebnis der Zuordnung eine Art verrauschte Gleichverteilung über \mathcal{C} . Dieses Ergebnis ist erwartet und liegt darin begründet, dass in der zugrunde gelegten Konzeptmenge \mathcal{C} kein passendes Konzept enthalten ist.

Die Repräsentant-zu-Konzept Zuordnung nach Gleichung (6.7) wird innerhalb der Verfahren der adaptiven Umweltmodellierung eingesetzt. Eine erweiterte Demonstration des vorgestellten Ansatzes anhand eines umfangreicheren Szenarios wird im Rahmen der Evaluation der adaptiven Umweltmodellierung in Kapitel 8.5 beschrieben. Eine tiefere Betrachtung der




Abbildung 6.1: Beispielhafte Ergebnisse der Repräsentant-zu-Konzept Zuordnung für unterschiedliche Repräsentanten und die betrachtete Menge von Konzepten $\mathcal{C} = \{\text{Apfel}, \text{Banane}, \text{Kokosnuss}\}$.

Eigenschaften des Ansatzes, vor allem in Bezug auf die Normierung der Zuordnungswahrscheinlichkeiten, wird nachfolgend vorgestellt.

6.4 Erweiterung der Zuordnung durch Nutzung von A-priori-Wissen

Die Repräsentant-zu-Konzept Zuordnung wird innerhalb der probabilistischen Informationsverwaltung genutzt, um Repräsentanten mit semantischen Attributen anreichern zu können. Sie stellt auch eine Grundlage für eine quantitative Modellbewertung in der adaptiven Umweltmodellierung dar. Dabei erfolgt die Zuordnung probabilistisch in Form einer Wahrscheinlichkeitsverteilung. Bei der Zuordnung eines Repräsentanten zu Konzepten des Hintergrundwissens lassen sich nun zwei Extremfälle unterscheiden: einerseits kann ein Repräsentant gegeben sein, welcher eindeutig einem Konzept zugeordnet werden kann, wie z. B. in den Abbildungen 6.1a und 6.1b dargestellt. Andererseits kann die Situation vorliegen, dass ein Repräsentant keinem der betrachteten Konzepte erfolgreich zugeordnet werden kann. In diesem Fall ergibt sich eine inkonklusive Wahrscheinlichkeitsverteilung als Ergebnis, wie z. B. in Abbildung 6.1c gezeigt. In allen Fällen wird die Wahrscheinlichkeitsverteilung mittels Gleichung (6.7) berechnet. Hierbei werden zunächst die Zuordnungswerte für alle betrachteten Konzepte zu einem Repräsentanten berechnet. Anschließend werden diese Werte normiert. Im

Fall, dass ein Repräsentant keinem Konzept eindeutig zugeordnet werden kann, kann diese Normierung zu Problemen führen.

6.4.1 Effekte der Normierung

Der Kern dieser Probleme ist dabei die Tatsache, dass eine Normierung agnostisch ist für eine Unterscheidung von signifikanten gegenüber insignifikanten Abweichungen in den Zuordnungswerten. Zur Veranschaulichung soll folgende Situation betrachtet werden. Für eine Menge von zwei Konzepten seien zwei unterschiedliche Mengen von Zuordnungswerten gegeben, welche normiert werden sollen. Im ersten Fall seien die Zuordnungswerte $\{0.9, 0.1\}$ gegeben, im zweiten Fall die Zuordnungswerte $\{0.0009, 0.0001\}$. Der erste Fall modelliert dabei eine verrauschte, aber relativ eindeutige Übereinstimmung eines betrachteten Repräsentanten mit dem ersten Konzept. Die zweite Menge von Zuordnungswerten beschreibt dagegen den betrachteten inkonklusiven Fall. Eine direkte Normierung dieser Zuordnungswerte führt in beiden Fällen dazu, dass der Repräsentant mit einer Wahrscheinlichkeit von 90% dem ersten Konzept zugeordnet wird. Im ersten Fall ist dies erwünscht, im zweiten Fall allerdings nicht. Hier wäre eine inkonklusive Wahrscheinlichkeitsverteilung ein angemessenes Zuordnungsergebnis.

Die Normierungsproblematik kann nun den ungewünschten Effekt in der Repräsentant-zu-Konzept Zuordnung haben, dass ein Repräsentant immer dem ähnlichsten Konzept zugeordnet wird, unabhängig davon, ob überhaupt eine signifikante Ähnlichkeit zwischen Repräsentant und Konzept besteht. Diese Situation, in Abbildung 6.2 nochmals dargestellt, entspricht jedoch nicht dem beabsichtigten Vorgehen einer Repräsentant-zu-Konzept Zuordnung. Daher muss eine Möglichkeit gefunden werden, solche Effekte verhindern zu können.

Ein erster Ansatz, um das Auftreten dieses Effekts zu verhindern, liegt in der Verwendung eines einfachen Schwellwerts, z. B. analog zu [Bel17]. Dabei kann der Schwellwert genutzt werden, um alle Zuordnungswerte, die




Abbildung 6.2: Beispiel für eine Repräsentant-zu-Konzept Zuordnung mit dem ungewünschten Effekt, dass durch die Normierung keine Unterscheidung von signifikanten gegenüber insignifikanten Zuordnungswerten gegeben ist (Teilabbildung (a)). Betrachtet werden der Repräsentant *Erdbeere1* und die Konzeptmenge $\{\text{Apfel, Banane, Kokosnuss}\}$, wie in den Tabellen 6.1 und 6.2 definiert. Teilabbildung (b) stellt das gewünschte Ergebnis dar.

unterhalb des Schwellwerts liegen, im Gesamtergebnis zu ignorieren. Praktisch kann dies z. B. erreicht werden, indem vor der Normierung alle Zuordnungswerte mit dem Schwellwert verglichen werden. Sind alle Werte kleiner als der Schwellwert, so wird als Ergebnis eine inkonklusive Verteilung zurückgegeben, anderenfalls erfolgt eine standardmäßige Normierung. Die Schwierigkeit dieses Ansatzes liegt nun in der Definition eines geeigneten Schwellwerts. Dies liegt darin begründet, dass die berechneten Zuordnungswerte nicht nur von der Ähnlichkeit des betrachteten Repräsentanten und Konzepts anhängen. Weiterhin gehen auch Faktoren wie z. B. die verwendeten Wertebereiche der Attribute sowie, im Speziellen, die zur Darstellung stetiger Attribute genutzten Maßeinheiten in die Berechnung mit ein. In Abhängigkeit dieser Faktoren kann bereits die Größenordnung der Zuordnungswerte variieren. Anteile wie Wertebereiche und Maßeinheiten werden in der objektorientierten Umweltmodellierung dabei erst auf der Ebene von Domänen- oder Anwendungsmodellen festgelegt (vgl. Abschnitt 4.5). Die Repräsentant-zu-Konzept Zuordnung stellt dagegen ein grundlegendes Verfahren der objektorientierten Umweltmodellierung dar, dessen Abhängigkeiten von Aspekten der Domänen- und Anwendungsmodellierung möglichst minimiert werden sollten. In dieser Arbeit wird daher ein erweiterter Ansatz betrachtet, um das Auftreten des ungewünschten Normierungseffekts in der Repräsentant-zu-Konzept Zuordnung verhindern zu

können. Der nachfolgend vorgestellte Ansatz wurde in [Kuw16] vorgestellt und basiert auf der Nutzung von A-priori-Wissen zur Unterscheidung von signifikanten gegenüber insignifikanten Zuordnungswerten.

6.4.2 Erweiterte Repräsentant-zu-Konzept Zuordnung

Die Ursache des beschriebenen Normierungseffekts liegt im Problem zu entscheiden, ob ein gegebener Zuordnungswert eine signifikante Ähnlichkeit zwischen Repräsentant und Konzept beschreibt oder nicht. Um diese Frage beantworten zu können, wird Wissen darüber benötigt, welche Größenordnung für berechnete Zuordnungswerte zu erwarten ist. Dieselbe Frage muss ebenfalls für die Festlegung eines Schwellwerts beantwortet werden. In Bezug auf einen absoluten Wert ist diese Frage nur sehr schwer zu beantworten, da eine Antwort im Allgemeinen auch vom vorliegenden Anwendungsfall abhängt. Eine Möglichkeit, die Größenordnung erwarteter Zuordnungswerte abschätzen zu können, ist durch eine relative Betrachtung gegeben. Zu diesem Zweck wird in dieser Arbeit A-priori-Wissen eingesetzt. Dieses A-priori-Wissen betrifft dabei priore Verteilungen für die in einem Anwendungsfall betrachteten Qualitäten.

Das grundlegende Vorgehen für eine Erweiterung der Repräsentant-zu-Konzept Zuordnung besteht nun darin, einen berechneten Zuordnungswert zu einem Wert in Bezug zu setzen, welcher den betrachteten Repräsentanten mit A-priori-Attributwerten vergleicht. Der Vergleich mit A-priori-Attributwerten kann dabei auf dieselbe Art und Weise berechnet werden wie der Vergleich mit einem Konzept. Dieser Vergleich liefert einen Basiswert. Berechnete Zuordnungswerte können nun relativ zu diesem Basiswert betrachtet und bewertet werden. Dabei kann dieser Basiswert z. B. als ein kontextsensitiver Schwellwert verstanden und genutzt werden: Zuordnungswerte unterhalb dieses Basiswerts werden als insignifikant angesehen.

In Bezug auf die Verwendung von A-priori-Verteilungen müssen weiterhin zwei Aspekte beachtet werden. Zum einen sind A-priori-Verteilungen für die Qualitäten eines Anwendungsfalls ebenfalls nicht unabhängig von der

Domänen- und Anwendungsmodellierung. Zum anderen stellen solche Verteilungen weitere Informationsartefakte dar, die während einer probabilistischen Modellierung der Domäne zu erstellen sind. Beide Aspekte hängen nun eng mit der Frage zusammen, wie solche A-priori-Verteilungen modelliert werden können. In dieser Arbeit wurden diesbezüglich unterschiedliche Ansätze betrachtet, welche nachfolgend vorgestellt werden.

Modellierung von A-priori-Verteilungen für Qualitäten

Die Grundidee für eine Modellierung solcher A-priori-Verteilungen in dieser Arbeit ist es, solche Verteilungen möglichst automatisiert aus den in einem Domänenmodell gegebenen Informationen ableiten zu können. Die A-priori-Verteilungen sind bei diesem Vorgehen zwar weiterhin von der Domänenmodellierung abhängig. Allerdings ist nun aber kein manuelles Eingreifen zur Parametrierung der Repräsentant-zu-Konzept Zuordnung mehr notwendig, wie dies z. B. beim manuellen Einstellen von Schwellwerten der Fall wäre. Somit ist diese Grundidee geeignet, beide der oben genannten Aspekte zu adressieren. Ein erster Ansatz zur Ableitung von A-priori-Verteilungen ist es, für jede Qualität eine Gleichverteilung über ihrem Wertebereich als A-priori-Verteilung zu definieren. Bei diesem Ansatz wird somit nur das Wissen über den Wertebereich einer Qualität benötigt. Dieses Wissen ist in der objektorientierten Umweltmodellierung im jeweiligen Domänenmodell hinterlegt.

Ein zweiter Ansatz ist es, nicht nur den Wertebereich einer Qualität als Information in eine A-priori-Verteilung einfließen zu lassen, sondern auch tatsächliches Vorwissen über die Verteilung der Werte relevanter Entitäten für diese Qualität. Solche Informationen sind in einem Domänenmodell in Form der Konzept-Verteilungen der Attribute zu dieser Qualität verfügbar. Eine A-priori-Verteilung für eine Qualität kann also definiert werden, indem eine gewichtete Summe aus den Verteilungen aller probabilistisch modellierten Konzepte gebildet wird (bzw. aller Konzepte in \mathcal{C}). Die Verwendung einer solchen rein summierten Verteilung zur Berechnung eines Basiswerts für

die Repräsentant-zu-Konzept Zuordnung bietet allerdings noch keinen Vorteil. Dies liegt darin begründet, dass Repräsentanten, welche zu keinem der modellierten Konzepte hinreichend ähnlich sind, auch beim Vergleich mit einer summierten Verteilung dieser Konzepte keine hinreichende Ähnlichkeit aufweisen. Anschaulich gesprochen liegen die Repräsentanten in Bereichen, in welchen keines der Konzepte eine signifikante Wahrscheinlichkeitsmasse aufweist. Folglich weist auch die summierte Verteilung der Konzepte in solchen Bereichen i. A. keine oder nur eine sehr geringe Wahrscheinlichkeitsmasse auf. Ein derartiges Problem besteht bei der Verwendung einer Gleichverteilung als A-priori-Verteilung im Übrigen nicht. Für den zweiten Ansatz ist es somit notwendig, auch in nicht von den Konzepten abgedeckten Bereichen eine nicht verschwindende Wahrscheinlichkeit zu definieren. Die Werte einer Wahrscheinlichkeitsverteilung in solchen Bereichen sollten dabei von den gegebenen Konzept-Verteilungen beeinflusst werden. Dies kann z. B. erreicht werden, indem die berechnete summierte Verteilung anschließend durch eine Generalisierungsoperation verallgemeinert wird. Anschaulich gesprochen entspricht dies einer Verbreiterung der Verteilung, bei welcher ein Teil der Wahrscheinlichkeitsmasse in die Bereiche abfließt, welche den Konzept-Verteilungen benachbart sind. Für eine solche Generalisierung können die in Abschnitt 8.4.3 beschriebenen Verfahren des Konzeptlernens eingesetzt werden, falls als stetige Konzept-Verteilungen nur Normal- und Gaußmischverteilungen vorkommen.

Somit können zwei unterschiedliche Ansätze genutzt werden, um A-priori-Verteilungen für Qualitäten automatisiert abzuleiten. Die Verwendung von Gleichverteilungen über den definierten Wertebereichen bietet dabei den Vorteil, dass der Ansatz einfach ist und keine weiteren Anforderungen besitzt. Der zweite Ansatz beruht auf der Generalisierung einer über die Konzept-Attribute summierten Verteilung. Diese Verteilung ist dabei informativer als eine reine Gleichverteilung, was bei der Normierung von Zuordnungswerten vorteilhaft sein kann. Um diesen zweiten Ansatz nutzen zu können, ist allerdings eine ausreichende Anzahl an für eine Anwendung repräsentativen Konzepten erforderlich. Anderenfalls kann es passieren, dass die Abdeckung der generalisierten Wahrscheinlichkeitsverteilung für die Wertebereiche einzelner Qualitäten nur unzureichend ist.

Nutzung von A-priori-Verteilungen zur Normierung

Unter der Annahme, dass für jede relevante Qualität eine A-priori-Verteilung gegeben ist, kann die Repräsentant-zu-Konzept Zuordnung durch eine verbesserte Normierung erweitert werden. Die Verbesserung basiert dabei auf der Unterscheidung von signifikanten gegenüber insignifikanten Zuordnungswerten zwischen Repräsentanten und Konzepten.

Eine Umsetzung dieser Unterscheidung erfolgt durch den Vergleich von Zuordnungswerten mit einem Basiswert, welcher unter Verwendung der A-priori-Verteilungen für die Attribute abgeleitet wird. Ein solcher Vergleich kann nun an unterschiedlichen Stellen in der Berechnung der Repräsentant-zu-Konzept Zuordnung erfolgen. Einerseits können bereits die attributbasierten Zuordnungswerte darauf geprüft werden, ob sie eine signifikante Ähnlichkeit des Repräsentanten-Attributs zum jeweils betrachteten Konzept-Attribut beschreiben. Andererseits können auch erst die kombinierten Zuordnungswerte auf eine signifikante Ähnlichkeit zwischen Repräsentant und betrachtetem Konzept geprüft werden. Beide Möglichkeiten wurden in dieser Arbeit betrachtet.

Der in dieser Arbeit verfolgte Ansatz basiert allgemein auf der Idee, die auftretenden Zuordnungswerte interpretierbar zu machen und unabhängig von einem Anwendungsfall darzustellen. Als interpretierbare Größe wird hier eine Darstellung der Zuordnungswerte in Form von Vielfachen der Basiswerte angesehen. Dies betrifft zunächst die pro Konzept berechneten attributbasierten Zuordnungswerte $\int_{\mathbb{R}} p_{a^r,i}(a) \cdot p_{a^0,i}(a) da$. Diese werden in einem ersten Ansatz als Vielfache der Basiswerte dargestellt, welche sich über das zuvor genannten Integral ergeben, wenn die Verteilung des Konzept-Attributs durch die entsprechende A-priori-Verteilung ersetzt wird. Ein attributbezogener Basiswert $b(a^{r,i})$ ergibt sich also als

$$b(a^{r,i}) := \int_{\mathbb{R}} p_{a^r,i}(a) \cdot p_{a^0,i}(a) da , \quad (6.8)$$

wobei $p_{a^0,i}(a)$ die zu $a^{r,i}$ korrespondierende A-priori-Verteilung darstellt. Für diskrete Attribute wird das Integral durch eine Summe ersetzt, analog

zum Vorgehen für Gleichung (6.7). Ein kombinierter Basiswert $b(r)$ für einen Repräsentanten r kann analog zur Kombination der attributbasierten Zuordnungswerte als $b(r) := \prod_{a^{r,i} \in \mathcal{A}_r} b(a^{r,i})$ berechnet werden. Mit diesen Definitionen können die als Vielfache der Basiswerte skalierten attributbasierten Zuordnungswerte somit als

$$p(c | a^{r,i})_{\text{prä}} := \frac{\int_{\mathbb{R}} p_{a^{r,i}}(a) \cdot p_{a^c,i}(a) da}{b(a^{r,i})} \quad (6.9)$$

beschrieben werden. Diese prä-skalierten Zuordnungswerte lassen sich anschließend wie zuvor durch das beschriebene iterative Vorgehen zu einem kombinierten Zuordnungswert pro Konzept zusammenfügen. Dabei stellt auch dieser kombinierte Zuordnungswert eine interpretierbare Größe dar, nämlich ein Vielfaches des Produkts der Basiswerte $b(r)$. Der kombinierte Zuordnungswert kann somit gegen einen vorab definierten Schwellwert verglichen werden, um zu entscheiden, ob eine signifikante Ähnlichkeit des verglichenen Repräsentanten r zum betrachteten Konzept c vorliegt. Ein entsprechender Schwellwert kann bei diesem Ansatz bereits zur Entwurfszeit und unabhängig vom konkreten Anwendungsfall festgelegt werden. Nichtsdestotrotz stellt ein solcher Schwellwert einen weiteren zu definierenden Parameter für die probabilistische Informationsverwaltung dar.

Der Vergleich der kombinierten Zuordnungswerte pro Konzept gegen einen Schwellwert liefert einen Hinweis, ob eine signifikante Ähnlichkeit zu einem Konzept vorliegt oder nicht. Als Ergebnis der Repräsentant-zu-Konzept Zuordnung wird allerdings eine Wahrscheinlichkeitsverteilung über allen betrachteten Konzepten erwartet. Somit muss in einem entsprechenden Ansatz also noch eine Normierung durchgeführt werden, unter Beachtung der Ergebnisse des Schwellwertvergleichs. Dies kann über eine Fallunterscheidung erfolgen: überschreitet der kombinierte Zuordnungswert für mindestens eines der betrachteten Konzepte den Schwellwert, so wird eine standardmäßige Normierung durchgeführt. Ist dies nicht der Fall, liegen also alle kombinierten Zuordnungswerte unterhalb des Schwellwerts, so wird eine

angepasste Normierung durchgeführt. Für eine solche angepasste Normierung sind nun ebenfalls unterschiedliche Vorgehen denkbar. Beispielsweise könnte, unabhängig von den gegebenen Zuordnungswerten, einfach eine Gleichverteilung als Ergebnis zurückgegeben werden. Andererseits kann auch die in den Zuordnungswerten enthaltene Information über deren relative Größen zueinander für eine Normierung beachtet werden. In dieser Arbeit wurde dabei ein Vorgehen gewählt, in welchem die Zuordnungswerte anteilig in die aus der Normierung resultierende Verteilung eingehen. Dazu wird für eine angepasste Normierung zunächst zu jedem kombinierten Zuordnungswert ein weiterer Wert addiert, bevor anschließend eine Normierung erfolgt. Für das Ergebnis der Normierung spielt dabei das Verhältnis zwischen addiertem Wert und den gegebenen Zuordnungswerten eine Rolle. Dieses Verhältnis bestimmt, wie sehr die Unterschiede zwischen den kombinierten Zuordnungswerten pro Konzept in das Ergebnis der Normierung eingehen. Eine auf das bisherige Vorgehen abgestimmte Möglichkeit ist die Angabe des zu addierenden Werts in Form eines Vielfachen des kombinierten Basiswerts $b(r)$. Im Falle einer angepassten Normierung liegen per Definition alle kombinierten Zuordnungswerte unterhalb des Schwellwerts, welcher als ein Vielfaches des kombinierten Basiswerts definiert ist. Gleichzeitig wird nun ein Vielfaches dieses Basiswerts als zu addierender Wert genutzt. Durch dieses Vorgehen lässt sich somit gezielt einstellen, wie stark die Unterschiede in den Zuordnungswerten in die resultierende Zuordnungswahrscheinlichkeit einfließen sollen. Je höher der addierte Wert, desto mehr wird sich die resultierende Wahrscheinlichkeitsverteilung einer Gleichverteilung annähern. Dieses Vorgehen wird zur Parametrierung der angepassten Normierung einer erweiterten Repräsentant-zu-Konzept Zuordnung genutzt.

Die sich nach der Normierung ergebende Wahrscheinlichkeitsverteilung stellt schließlich das Ergebnis der Repräsentant-zu-Konzept Zuordnung dar. Das zuvor beschriebene Vorgehen stellt einen ersten Ansatz zur Erweiterung der Repräsentant-zu-Konzept Zuordnung dar. Dieser Ansatz wird als Prä-Skalierung¹ bezeichnet (vgl. Gleichung (6.9)), da hier eine Skalierung der

¹ In [Kuw16] wird der Ansatz im Englischen als „Leveling“ bezeichnet, mit Bezug auf das Einbrennen der normierten Verteilung im Falle eines nicht zuordenbaren Repräsentanten.

attributbasierten Zuordnungswerte bereits vor ihrer Kombination erfolgt. Für eine Umsetzung des Ansatzes zu Demonstrationszwecken wurde als Schwellwert das 1.5-fache des kombinierten Basiswerts $b(r)$ gewählt und als zu addierender Wert der Basiswert selbst. Der Ansatz der Prä-Skalierung zeichnet sich durch eine Fallunterscheidung aus. Liegt eine signifikante Ähnlichkeit des gegebenen Repräsentanten zu einem oder mehreren der betrachteten Konzepte vor, so erfolgt keine Anpassung der Normierung, anderenfalls schon. Durch diese Fallunterscheidung bleibt die Zuordnungswahrscheinlichkeit im Falle einer signifikanten Ähnlichkeit unverändert. Die Berechnung dieser Zuordnungswahrscheinlichkeit erfolgt aufgrund der Fallunterscheidung allerdings nicht mehr einheitlich. Eine Möglichkeit, beide Fällen einheitlich zu betrachten, wird in einem zweiten Ansatz zur Erweiterung der Repräsentant-zu-Konzept Zuordnung vorgestellt.


Dieser zweite, als Post-Skalierung bezeichnete Ansatz kombiniert die attributbasierten Zuordnungswerte ohne vorherige Skalierung. Eine Skalierung erfolgt in diesem Ansatz erst für die kombinierten Zuordnungswerte. Dabei wird jeder dieser Zuordnungswerte als

$$p(c|r)_{\text{post}} := \frac{p(c|r) + b(r)}{b(r)} \quad (6.10)$$

skaliert. Anstelle der beiden Basiswerte $b(r)$ können auch hier Vielfache genutzt werden, um die Skalierung entsprechend einzustellen. In dieser Arbeit werden für den zweiten Ansatz allerdings direkt die Basiswerte genutzt. Dieser zweite Ansatz stellt eine Erweiterung der Repräsentant-zu-Konzept Zuordnung in geschlossener Form dar. Ein Nachteil dieses Ansatzes ist jedoch, dass auch die Zuordnungswahrscheinlichkeit im Falle einer signifikanten Ähnlichkeit etwas in Richtung einer Gleichverteilung verschoben wird. Diese „Verwässerung“ liegt darin begründet, dass bei diesem Ansatz immer der kombinierte Basiswert zum Zuordnungswert addiert wird. Dieser Effekt wird z. B. in Abbildung 6.3b sichtbar.

6.4.3 Evaluation der erweiterten Zuordnung

Die vorgeschlagenen Erweiterungen der Repräsentant-zu-Konzept Zuordnung wurden ebenfalls für das in Abschnitt 6.3.2 vorgestellte einfache Demonstrationsszenario evaluiert. Ergebnisse dieser Evaluation sind in Abbildung 6.3 dargestellt. Dabei wurde wieder wie bisher die beispielhafte Konzeptmenge $\{\text{Apfel}, \text{Banane}, \text{Kokosnuss}\}$ betrachtet sowie die beiden Repräsentanten *Apfel1* und *Erdbeere1*, wie in den Tabellen 6.1 und 6.2 definiert. Zuerst wird die Zuordnung von *Apfel1* zur Konzeptmenge betrachtet, wobei als Ergebnis eine eindeutige Zuordnung zum Konzept *Apfel* erwartet wird. Abbildung 6.3a stellt das Zuordnungsergebnis für den ersten Ansatz mit Prä-Skalierung dar, Abbildung 6.3b das Ergebnis für den zweiten Ansatz mit Post-Skalierung. Die Wahrscheinlichkeitsverteilung der Zuordnung entspricht für beide Ansätze dem erwarteten Ergebnis. Für die Post-Skalierung ist die leichte „Verwässerung“ der Verteilung zu erkennen. In Abbildung 6.3c ist die Zuordnung des Repräsentanten *Erdbeere1* zur Konzeptmenge unter Anwendung des ersten Ansatzes dargestellt. Im Gegensatz zum bisherigen Ergebnis der Repräsentant-zu-Konzept Zuordnung (vgl. Abbildung 6.2a) wird durch die Erweiterung nun auch in diesem Fall, wie gewünscht, eine inkonklusive Wahrscheinlichkeitsverteilung als Zuordnung zurückgegeben.



- (a) Erweiterte Zuordnung für Repräsentant *Apfel1* mit Prä-Skalierung
- (b) Erweiterte Zuordnung für Repräsentant *Apfel1* mit Post-Skalierung
- (c) Erweiterte Zuordnung für Repräsentant *Erdbeere1* mit Prä-Skalierung

Abbildung 6.3: Beispielhafte Ergebnisse der erweiterten Repräsentant-zu-Konzept Zuordnung unter Verwendung von A-priori-Verteilungen. Dabei werden zwei Repräsentanten (*Apfel1*, *Erdbeere1*) der Konzeptmenge $\{\text{Apfel}, \text{Banane}, \text{Kokosnuss}\}$ zugeordnet unter Verwendung der Ansätze mit Prä- oder Post-Skalierung der Zuordnungswerte. Wie erwartet kann *Apfel1* durch beide Ansätze eindeutig zugeordnet werden, wobei die Post-Skalierung zur einer leichten Verwässerung führt. Für *Erdbeere1* ergibt sich wie gewünscht eine inkonklusive Verteilung.

Neben der Evaluation in einem Demonstrationsszenario, welche die grundsätzliche Anwendbarkeit demonstriert, wird die erweiterte Repräsentant-zu-Konzept Zuordnung auch in einem komplexeren Anwendungsszenario evaluiert. Die entsprechenden Ergebnisse werden in Kapitel 8 beschrieben. Eine weitere Evaluation findet auch zusammen mit der nachfolgend beschriebenen quantitativen Modellbewertung statt.

6.5 Zusammenfassung

In diesem Kapitel wurde die Repräsentant-zu-Konzept Zuordnung in der objektorientierten Umweltmodellierung betrachtet. Nach einer allgemeinen Einführung in die Thematik wurde mit [Bel17] ein existierender Ansatz diskutiert. Da dieser Ansatz sich an einigen Stellen von den in dieser Arbeit getroffenen Grundannahmen unterscheidet, wurde anschließend ein eigener alternativer Ansatz vorgestellt. Für diesen Ansatz wurde das Thema der Normierung vertieft betrachtet und es wurden verschiedene Erweiterungen vorgeschlagen, welche unter der Verwendung von A-priori-Wissen eine verbesserte Normierung ermöglichen. Alle vorgeschlagenen Ansätze wurden an einem Demonstrationsszenario in Bezug auf ihre grundsätzliche Anwendbarkeit evaluiert. Diese Ansätze zur Repräsentant-zu-Konzept Zuordnung finden Anwendung in der nachfolgend vorgestellten adaptiven Umweltmodellierung. Die in diesem Kapitel beschriebenen eigenen Ergebnisse wurde in [Kuw13b] sowie [Kuw16] veröffentlicht.

7 Quantitative Modellbewertung

Das zentrale Thema dieser Arbeit ist die Erweiterung der objektorientierten Umweltmodellierung hin zu einer adaptiven Umweltmodellierung, welche in Kapitel 3 im Überblick vorgestellt wurde. Dabei wurden u. a. die der adaptiven Umweltmodellierung zugrunde gelegten Prinzipien dargelegt und ihre unterschiedlichen Aufgaben vorgestellt. Eine wichtige Aufgabe ist dabei durch die quantitative Bewertung der Güte eines Hintergrundwissensmodells gegeben. Die Güte eines Hintergrundwissensmodells quantifiziert dabei, wie sehr ein Modell in der Lage ist, die beobachtete Umgebung und ihre Entitäten zu beschreiben und zu erklären. Diese Modellgüte stellt dabei im Gegensatz zu anderen Bewertungsmaßen der adaptiven Umweltmodellierung ein globales Maß für das objektorientierte Umweltmodell dar. Sie kann daher dazu dienen, die adaptive Wissensverwaltung auf einer übergeordneten Ebene zu steuern und zu koordinieren. Der Ansatz der quantitativen Modellbewertung wurde in [Kuw13a] vorgestellt.

In der Modellbewertung wird betrachtet, wie gut ein Hintergrundwissensmodell dazu geeignet ist, die Repräsentanten des Weltmodells durch ihre zugeordneten Konzepte im Hintergrundwissen zu beschreiben. Die Annahmen, die bezüglich des Hintergrundwissensmodells und der betrachteten Konzeptmenge $\mathcal{C} \subset \mathcal{C}_0$ getroffen werden, decken sich daher mit den Annahmen, die in Abschnitt 6.1.3 für den vorgestellten alternativen Ansatz der Repräsentant-zu-Konzept Zuordnung getroffen wurden. So wird beispielsweise ebenfalls ein flaches Wissensmodell \mathcal{C} angenommen. Für die darin enthaltenen Konzepte werden ebenfalls nur deskriptive Attribute betrachtet, d. h. perzeptive, nicht zustandsbezogene Attribute und eventuell ausgewählte deduktive Attribute. Die genannten Attributmengen für Konzepte \mathcal{A}_c und Repräsentanten \mathcal{A}_r beziehen sich in diesem Abschnitt ebenfalls auf

diese deskriptiven Attribute, wenn nicht explizit anders angegeben. Die Betrachtung nur solcher Attribute ist auch hier rein semantisch motiviert. Für die entworfenen Verfahren spielt der Szenarmodus der Attribute keine Rolle. Weiterhin wird in der Modellbewertung die Annahme getroffen, dass die betrachtete Konzeptmenge \mathcal{C} pro Zweig der „is-a“-Generalisierungshierarchie nur ein Konzept enthält. Eine Bewertung der hierarchischen Strukturierung eines Wissensmodells erfolgt somit nicht.

7.1 Gewähltes Vorgehen

Zur Entwicklung eines Maßes für die quantitative Bewertung von Hintergrundwissensmodellen wurde ein Ansatz gewählt, welcher auf dem Prinzip der minimalen Beschreibungslänge (MDL¹, z. B. [Grü07]) basiert.

7.1.1 Das Prinzip der minimalen Beschreibungslänge

Das MDL-Prinzip kann als ein Informationskriterium zur Modellselektion eingesetzt werden. Das Problem der Modellselektion besteht darin, für eine gegebene Menge von Daten $D := \{x_i, y_i\}$ ein passendes Modell zu finden. Dabei kann z. B. eine Regressionsaufgabe vorliegen, in welcher als Modell ein funktionaler Zusammenhang $y = h(x)$ zwischen x und y gefunden werden soll. Nach dem Prinzip der minimalen Beschreibungslänge [Ris78] kann ein Modell verwendet werden, um die Daten $\{x_i, y_i\}$ komprimiert darzustellen. Dazu müssen zunächst Regularitäten in den Daten gefunden werden. Diese können anschließend in einem Modell abgebildet werden [Grü07]. Unter Verwendung dieses Modells ist nun eine komprimierte Darstellung der Daten möglich. Anstelle einer Darstellung der Daten als (x_i, y_i) -Paare müssen bei Verwendung eines Modells nur noch die x -Werte und das Modell selbst dargestellt werden. Die y -Werte können für gegebene x -Werte dann jeweils aus dem Modell berechnet werden. In realen Anwendungsfällen sind die Daten $\{x_i, y_i\}$ jedoch häufig verrauscht, so dass i. A. keine exakte Darstellung

¹ Englisch: minimum description length

der y -Werte durch die Modellwerte $h(x)$ möglich ist. In diesem Fall kann anstelle eines y -Werts nur noch seine Abweichung vom Modellwert $h(x)$ dargestellt werden. Für die Darstellung von Daten mittels eines Modells gilt allgemein: je besser das Modell zu den Daten passt, desto weniger Beschreibung wird zur Darstellung der Daten benötigt [Grü07]. Je besser also ein Modell in der Lage ist, die gegebenen y -Werte zu beschreiben, desto weniger Beschreibung wird für die Darstellung ihrer Abweichung von den Modellwerten $h(x)$ benötigt.

Nach dem MDL-Prinzip wird nun aus einer gegebenen Menge von Modellen dasjenige Modell ausgewählt, welches die geringste Beschreibungslänge besitzt. Das MDL-Prinzip stellt dabei einen ganzheitlichen Ansatz dar, in welchem neben der Beschreibungslänge der Daten auch die Beschreibungslänge des Modells selbst mit eingeht. Eine erhöhte Beschreibungslänge für ein Modell korrespondiert dabei allgemein mit einem komplexeren Modell, welches auch in der Lage ist, komplexere funktionale Zusammenhänge zwischen den Daten $\{x_i, y_i\}$ zu beschreiben. Komplexere Modelle zeichnen sich i. A. durch eine erhöhte Anzahl an Freiheitsgraden aus und erfordern somit auch eine längere Beschreibung. Im Gegenzug können komplexere Modelle eine genauere Beschreibung der Daten ermöglichen und vermögen so die Beschreibungslänge der Daten zu reduzieren.

Das MDL-Prinzip stellt nun der Beschreibungslänge der Daten, welche ein Maß für die Modellgüte darstellt, die Beschreibungslänge des Modells gegenüber. Diese stellt ein Maß für die Modellkomplexität dar. Ausgewählt wird dann dasjenige Modell, welches die geringste kombinierte Beschreibungslänge für Daten und Modell besitzt. Durch dieses ausbalancierte Vorgehen lässt sich eine Überanpassung des Modells an die Daten verhindern. Ein überangepasstes Modell neigt zum Auswendiglernen von Daten. Ein solches Modell liefert dann zwar gute Ergebnisse für genau diese Daten, generalisiert aber i. A. schlecht auf weitere, ungesehene Daten. Durch Anwendung des MDL-Prinzips kann eine solche Überanpassung verhindert werden.

7.1.2 MDL-basiertes Vorgehen

In dieser Arbeit wurde das MDL-Prinzip als Grundlage für eine quantitative Modellbewertung gewählt. Dies liegt darin begründet, dass die quantitative Modellbewertung eine ähnlich gelagerte Problemstellung beschreibt und eine Balance zwischen Modellkomplexität und Modellgüte auch in der Umweltmodellierung eine wünschenswerte Eigenschaft ist. Weiterhin ist das MDL-Prinzip als ein Informationskriterium auch geeignet, um in Bezug auf eine Steuerung der in der adaptiven Umweltmodellierung anfallenden Aufgaben auf einer übergeordneten Ebene angewendet zu werden. Diese Aufgaben betreffen z. B. die Änderungen und Anpassungen des Wissensmodells. Somit steuert die Modellbewertung ein globales Gütemaß für Hintergrundwissensmodelle zur adaptiven Umweltmodellierung bei.

Der grundlegende Ansatz zur quantitativen Modellbewertung wird in Abschnitt 7.2 beschrieben. Die Abschnitte 7.3 und 7.4 beschreiben anschließend, wie in der adaptiven Umweltmodellierung die Bewertung der Modellkomplexität und der Beschreibungslänge der Daten erfolgt. In Abschnitt 7.5 wird der Aufwand dieser quantitativen Modellbewertung diskutiert. Abschnitt 7.6 demonstriert schließlich die quantitative Modellbewertung an einem Beispielszenario und stellt Evaluationsergebnisse vor.

7.2 Grundlegender Ansatz

Ein Maß für eine quantitative Bewertung der Güte eines Hintergrundwissensmodells soll die Fähigkeit des Modells bewerten, die in einer beobachteten Umgebung angetroffenen Typen von Entitäten darstellen zu können. Diese Entitäten werden dabei durch die Repräsentanten im Weltmodell repräsentiert. In dieser Arbeit wird ein Vorgehen genutzt, welches dem MDL-Prinzip folgt. Dabei existieren unterschiedliche Ansätze zur Umsetzung des MDL-Prinzips [Grü07]. In dieser Arbeit wird konzeptionell auf einem einfachen Ansatz aufgesetzt.

7.2.1 Einfacher MDL-Ansatz

Der einfache Ansatz¹ zur Umsetzung des MDL-Prinzips wird von Grünwald [Grü07] beschrieben. Dabei wird die Güte eines Modells M durch das zusammengesetzte Maß

$$L(D) := L(D | M) + L(M) \quad (7.1)$$

für die Beschreibungslänge $L(D)$ der Daten D unter Anwendung des Modells M bewertet. Der erste Summand $L(D | M)$ repräsentiert die Beschreibungslänge der Daten D unter Verwendung des Modells. Der zweite Summand repräsentiert die Beschreibungslänge $L(M)$ für das Modell selbst. Diese beiden Terme sind im Allgemeinen negativ korreliert. Das bedeutet, dass es ein komplexeres Modell ermöglicht, die Daten auf eine kürzere Weise zu beschreiben. Die Betrachtung beider Terme zugleich bietet den beschriebenen Schutz vor einer Überanpassung des Modells an die Daten.

7.2.2 MDL-basierter Ansatz zur quantitativen Modellbewertung

Dieser einfache Ansatz nach dem MDL-Prinzip kann nun auf die Berechnung der quantitativen Modellgüte für die adaptive Umweltmodellierung übertragen werden. Relevante Anteile des objektorientierten Umweltmodells sind dabei die Menge der Konzepte $\mathcal{C} \subset \mathcal{C}_0$ im Hintergrundwissen, welche die Entitätstypen und somit die Zuordnungsziele für Repräsentanten darstellen. Weiter ist die Menge \mathcal{R} der im Weltmodell enthaltenen Repräsentanten ein wichtiger Parameter. Jeder Repräsentant $r \in \mathcal{R}$ wird dabei über seine (deskriptiven) Attribute \mathcal{A}_r beschrieben, jedes Konzept $c \in \mathcal{C}$ über die modellierten (deskriptiven) Attribute \mathcal{A}_c . Weiterhin spielt die probabilistische Zuordnung von Repräsentanten zu Konzepten in Form der bedingten Wahrscheinlichkeit $p(c|r)$ eine wichtige Rolle.

¹ In [Grü07] englisch als „crude MDL“ bezeichnet.

Auf Grundlage dieser Parameter kann ein quantitatives Maß $Q(\cdot)$ zur Modellbewertung in Analogie zum einfachen MDL-Ansatz (7.1) somit als

$$Q(\mathcal{R}, \mathcal{C}) := L(\mathcal{R} | \mathcal{C}) + L(\mathcal{C}) \quad (7.2)$$

definiert werden. Durch dieses Maß wird die Modellgüte bewertet. Dabei beschreibt der erste Summand $L(\mathcal{R} | \mathcal{C})$ die Korrespondenz der Repräsentanten im Weltmodell zu den betrachteten Konzepten des Hintergrundwissens. Der zweite Summand $L(\mathcal{C})$ beschreibt die Komplexität des Modells. Wie diese beiden Terme für das objektorientierte Umweltmodell berechnet werden können, wird in den nachfolgenden Abschnitten dargestellt.

7.3 Modellkomplexität

Als ein Anteil in der quantitativen Modellbewertung muss die Komplexität eines Hintergrundwissensmodells bewertet werden. Dem MDL-Prinzip folgend, sollte ein Bewertungsmaß dabei die Komplexität eines Modells proportional zu dessen Beschreibungslänge bewerten. Die Beschreibungslänge stellt die Länge einer entsprechenden Repräsentation des Modells dar, gemessen z. B. in der Anzahl benötigter Zeichen. Diese Vorstellung muss nun auf ein Maß für die Komplexität eines Hintergrundwissensmodells übertragen werden. Diesbezüglich werden in dieser Arbeit die nachfolgend dargestellten Grundannahmen getroffen.

Als relevantes Hintergrundwissen für die adaptive Umweltmodellierung wird die Teilmenge \mathcal{C} der zuordenbaren Konzepte betrachtet. Die Komplexität eines Hintergrundwissensmodells lässt sich somit als die Komplexität $L(\mathcal{C})$ dieser Konzeptmenge betrachten. Dabei wird weiterhin die Annahme gemacht, dass jedes in \mathcal{C} enthaltene Konzept c in gleichen Anteilen zur Gesamtkomplexität des Modells beiträgt. Die Modellkomplexität $L(\mathcal{C})$ kann daher als die Summe der individuellen Komplexitäten $L(c)$ der in \mathcal{C} enthaltenen Konzepte c berechnet werden.

7.3.1 Konzeptkomplexität

Unter dieser Annahme muss als nächstes die Komplexität eines einzelnen Konzepts betrachtet werden. Relevante Parameter eines Konzepts sind dabei Art, Anzahl und Werte seiner deskriptiven Attribute. Auch die Komplexität eines Konzepts soll proportional zur für das Konzept benötigten Beschreibungslänge bewertet werden. In dieser Arbeit wird nun von einem positiven Zusammenhang zwischen Beschreibungslänge eines Konzepts und dem Detaillierungsgrad dieser Beschreibung ausgegangen: je detaillierter ein Konzept beschrieben wird, desto größer ist die Länge der dafür benötigten Beschreibung. Detaillierter beschriebene Konzepte stellen somit komplexere Konzepte dar. Gleichzeitig repräsentieren detaillierter beschriebene Konzepte auch spezifischere Typen von Domänen-Entitäten in dem Sinne, dass die modellierten Eigenschaften dieser Entitäten genauer festgelegt sind. Zwischen der Komplexität eines Konzepts und seiner Spezifität besteht somit ebenfalls ein positiver Zusammenhang. Ein Konzept kann somit als desto komplexer betrachtet werden, je mehr (deskriptive) Attribute es besitzt. Denn die Angabe jedes Attributs erhöht den Detaillierungsgrad einer Beschreibung. Ein Konzept kann ebenfalls als komplexer betrachtet werden, je genauer die Eigenschaften von Entitäten in den modellierten Attributen beschrieben werden. Eine genauere Modellierung erhöht die Spezifität eines Konzepts und somit dessen Komplexität. Diese zweite Aussage betrifft allerdings bereits die Bewertung von Attributen. Für die Berechnung der Komplexität eines Konzepts folgt schließlich, dass je mehr (deskriptive) Attribute ein Konzept besitzt, als desto komplexer es gelten muss. Weiterhin kann angenommen werden, dass jedes Attribut in gleichen Teilen (jedoch abhängig von seiner konkreten Verteilung) zur Komplexität des Konzepts beiträgt. Somit lässt sich die Komplexität $L(c)$ eines Konzepts als die Summe der Komplexitäten $L(a^{c,i})$ seiner (deskriptiven) Attribute $a^{c,i} \in \mathcal{A}_c$ bewerten.

Berechnung der Modellkomplexität Setzt man nun die bisher getroffenen Annahmen zusammen, so kann die Komplexität $L(\mathcal{C})$ eines Hintergrundwissensmodells \mathcal{C} zusammengefasst als die Summe

$$L(\mathcal{C}) := \sum_{c \in \mathcal{C}} \sum_{a^{c,i} \in \mathcal{A}_c} L(a^{c,i}) \quad (7.3)$$

berechnet werden. Durch diesen Ansatz wird die Berechnung der Komplexität eines Hintergrundwissensmodells abgebildet auf eine Berechnung der Beschreibungslänge von Konzept-Attributen.

7.3.2 Attributkomplexität

Als nächstes müssen somit Attribute betrachtet werden. Die Komplexität $L(a^{c,i})$ eines Attributs wird auf Basis des dargestellten Attributwerts bewertet. In der objektorientierten Umweltmodellierung ist dieser Wert in Form einer DoB-Verteilung $p_{a^{c,i}}(a)$ gegeben. Somit stellt sich nun die Frage, wie die Komplexität der DoB-Verteilung eines modellierten Attributs bewertet werden kann. Wie zuvor motiviert, wird in dieser Arbeit von der Annahme ausgegangen, dass ein Attribut als komplexer zu betrachten ist, je spezifischer es seine Werte beschreibt. Diese Annahme überträgt sich auf die Bewertung der Attributverteilung. Dabei können Konzentrationsmaße eingesetzt werden, um zu bewerten, wie spezifisch eine Wahrscheinlichkeitsverteilung ihre Werte beschreibt. Die zugrunde liegende Annahme ist hierbei, dass durch eine stärker konzentrierte Attributverteilung weniger Werte für ein Konzept zulässig sind. Und je weniger Werte eines vorgegebenen Wertebereichs zulässig sind, desto spezifischer wird ein Attribut, und somit ein Konzept, beschrieben.

Komplexität diskreter Attribute

Als Konzentrationsmaß für Wahrscheinlichkeitsverteilungen wird in dieser Arbeit die Shannon'sche Entropie $H(\cdot)$ eingesetzt. Für ein diskretes Attribut a_d^c mit Wahrscheinlichkeitsverteilung $p_{a_d^c}(a)$ und Wertebereich S_a ergibt

sich diese Entropie als

$$H(a_d^c) = - \sum_{a \in S_a} p_{a_d^c}(a) \cdot \log(p_{a_d^c}(a)) . \quad (7.4)$$

Um mittels der Shannon'schen Entropie bewerten zu können, wie spezifisch ein modelliertes Attribut ist, wird folgender Ansatz genutzt. Je stärker konzentriert die Werte eines Attributs in seiner Verteilung modelliert sind, desto kleiner ist die Entropie dieser Verteilung. Gleichzeitig beschreiben stärker konzentrierte Werte auch ein spezifischeres Attribut. Entropie und Spezifität stehen also in einem negativen Zusammenhang. In Folge ist ein Attribut somit weniger komplex, je größer die Entropie seiner Verteilung ist. Der maximale Wert, den die Entropie einer Verteilung annehmen kann, wird von der Kardinalität des Wertebereichs S_a eines diskreten Attributs bestimmt. Dieser Maximalwert wird beim Vorliegen einer Gleichverteilung angenommen und ergibt sich als $\log(|S_a|)$. Dieser Fall beschreibt zugleich die minimale Komplexität, die ein Attribut bei einem vorgegebenen Wertebereich aufweisen kann. Für ein diskretes Attribut a_d^c mit Wertebereich S_a lässt sich die Komplexität $L(a_d^c)$ somit über den Ansatz

$$L_1(a_d^c) := \log(|S_a|) - H(a_d^c) \quad (7.5)$$

berechnen. Dieser Ansatz bezieht explizit die Größe des Wertebereichs S_a mit ein. Im Falle einer Gleichverteilung nimmt die Komplexität hier einen Wert von 0 an. Als maximalen Wert kann die Komplexität bei gegebenem Wertebereich einen Wert annehmen, der in seiner Größe dem Maximalwert der Entropie für diesen Wertebereich entspricht. Als Alternative zu diesem Ansatz kann auch eine in Bezug auf ihren Wertebereich normalisierte Komplexität definiert werden. Diese kann als

$$L_2(a_d^c) := 1 - \frac{H(a_d^c)}{\log(|S_a|)} \quad (7.6)$$

berechnet werden und nimmt nur Werte aus dem Intervall $[0,1]$ an.

Komplexität stetiger Attribute

Für die Verteilungen stetiger Attribute kann die Shannon'sche Entropie nicht direkt berechnet werden. Eine mögliche Alternative ist durch die Nutzung der sog. differentiellen Entropie $H(a) = - \int p_a(a) \cdot \log(p_a(a))$ da gegeben, als ein Maß der Entropie für stetige Zufallsvariablen. Diese differentielle Entropie unterscheidet sich allerdings von der Shannon'schen Entropie und besitzt einige für eine quantitative Modellbewertung nicht wünschenswerte Eigenschaften. Dazu zählt, dass die differentielle Entropie nicht skalierungsinvariant ist, was z. B. für in unterschiedlichen Maßeinheiten gegebene Attribute zu Problemen führen kann. Weiterhin kann die differentielle Entropie negative Werte annehmen, was problematisch für den dargelegten kumulativen Ansatz der Modellbewertung ist. Auch unterscheidet sich der Wert der differentiellen Entropie für eine stetige Verteilung von demjenigen Wert, gegen den eine Diskretisierung dieser Verteilung für ein gegen 0 gehendes Diskretisierungsintervall konvergiert [Cov91].

In dieser Arbeit wird daher nicht die differentielle Entropie zur Berechnung der Komplexität stetiger Attribute verwendet. Stattdessen werden stetige Attribute für eine Berechnung ihrer Komplexität zunächst diskretisiert. Dieses Vorgehen ist dabei von Arbeiten [Bel12a] im Bereich der objektorientierten Umweltmodellierung motiviert, in welchen die Unsicherheit bzgl. der Erkennung vorliegender Situationen bewertet werden soll.

Kleinster unterscheidbarer Betrag Die zugrunde liegende Idee geht dabei auf Oswald [Osw91] zurück und betrifft einen kleinsten unterscheidbaren Betrag¹ für ein stetiges Merkmal. Die Annahme ist dabei, dass für ein stetiges Merkmal ein kleinster Betrag angegeben werden kann, dessen Unterscheidung für die Anwendungsdomäne gerade noch relevant ist. So kann sich z. B. die benötigte Genauigkeit für Positionsangaben je nach Anwendungsdomäne unterscheiden. Eine natürliche Wahl für diesen kleinsten unterscheidbaren Betrag kann dabei anhand der Messunsicherheit der genutzten Sensorik getroffen werden [Bel12a]. Für die objektorientierte Umweltmodellierung

¹ Englisch: least discernible quantum (LDQ)

bedeutet die Verwendung solcher kleinster unterscheidbarer Beträge, dass diese Größen pro Qualität zusätzlich zu den bisherigen Angaben in einem Domänenmodell festgelegt werden müssen, und zwar zur Entwurfszeit des Systems. Somit muss auch das Metamodell des objektorientierten Umweltmodells um diesen Parameter erweitert werden.

Diskretisierung stetiger Attribute Unter Anwendung kleinster unterscheidbarer Beträge Δ_a kann ein stetiges Attribut a diskretisiert werden. Dazu wird der Wertebereich des Attributs in Intervalle der Länge Δ_a unterteilt. Jedem Intervall wird durch Integration diejenige Wahrscheinlichkeitsmasse zugeordnet, welche die stetige Wahrscheinlichkeitsverteilung über diesem Bereich insgesamt besitzt. Nach der Diskretisierung kann das durch Gleichung (7.5) definierte Komplexitätsmaß für diskrete Attribute angewendet werden. In dieses Komplexitätsmaß fließt neben der diskretisierten Wahrscheinlichkeitsverteilung auch die Mächtigkeit des diskretisierten Wertebereichs mit ein.

7.4 Modellkorrespondenz

Der zweite Summand neben der Modellkomplexität in der quantitativen Modellbewertung (7.2) beschreibt die Korrespondenz eines Hintergrundwissensmodells mit den im Weltmodell enthaltenen Repräsentanten. Das Analogon zu diesem Term nach MDL-Prinzip ist die Beschreibungslänge, welche benötigt wird, um gegebene Daten unter Verwendung eines betrachteten Modells zu beschreiben. Für die Modellbewertung nimmt die Menge der Repräsentanten \mathcal{R} die Rolle der Daten ein, und das Hintergrundwissensmodell \mathcal{C} die Rolle des Modells. Die vom MDL-Prinzip motivierte Grundannahme in dieser Arbeit ist, dass eine Beschreibung von Repräsentanten auf desto kürzere Weise erfolgen kann, je besser ein Repräsentant durch ein Konzept dargestellt werden kann. Genauer gesagt ist die anschauliche Idee, dass, wenn ein Repräsentant vollständig durch ein Konzept beschrieben werden kann, keine weitere Beschreibung mehr für diesen Repräsentanten notwendig ist. Ist dies nur teilweise möglich, besitzt ein Repräsentant also Anteile, die nicht von einem Konzept dargestellt

werden können, so fällt hingegen weiterer Beschreibungsaufwand an. Die Tatsache, dass ein Repräsentant durch ein Konzept beschrieben werden kann, wird dabei als Korrespondenz zwischen Repräsentant und Konzept bzw. zwischen Hintergrundwissen und Weltmodell bezeichnet, und die Stärke ihrer Ausprägung als Modellqualität.

7.4.1 Kumulative Berechnung der Modellkorrespondenz

Zur Bestimmung der Korrespondenz $L(\mathcal{R} | \mathcal{C})$ der Repräsentanten des Weltmodells zu den Konzepten des Hintergrundwissens wird ein ähnlicher Ansatz wie bei der Bewertung der Modellkomplexität gewählt. Dabei wird zunächst die individuelle Korrespondenz $L(r | c)$ eines Repräsentanten $r \in \mathcal{R}$ zu einem Konzept $c \in \mathcal{C}$ betrachtet. Die Modellkorrespondenz ergibt sich dann kumulativ als die Summe der individuellen Korrespondenzen über alle Repräsentanten. Es wird davon ausgegangen, dass jeder Repräsentant in gleichen Teilen zur Modellkorrespondenz beiträgt. Pro Repräsentant r existiert nun aber nicht nur ein Korrespondenzwert, sondern ein Korrespondenzwert von r zu jedem Konzept c . Somit stellt sich die Frage, wie diese Werte für die unterschiedlichen Konzepte in die Gesamtberechnung einfließen sollten. Von praktischer Relevanz ist in der objektorientierten Umweltmodellierung für einen Repräsentanten dasjenige Konzept, mit welchem es über die Repräsentant-zu-Konzept Zuordnung assoziiert wurde. Erfolgt diese Zuordnung in Form einer harten Entscheidung, dann fließt pro Repräsentant nur der Korrespondenzwert für dieses zugeordnete Konzept in die Modellkorrespondenz mit ein. Im Allgemeinen erfolgt die Zuordnung allerdings probabilistisch, d. h. in Form einer diskreten Wahrscheinlichkeitsverteilung über den Konzepten in \mathcal{C} . Diese diskrete Wahrscheinlichkeitsverteilung kann nun mehr als einem Konzept eine nichtverschwindende Zuordnungswahrscheinlichkeit zuweisen. Um auch in diesem Fall die Gesamtkorrespondenz eines Modells auf Basis der individuellen Korrespondenzen von Repräsentanten berechnen zu können, wird in dieser Arbeit die erwartete Korrespondenz auf Basis der Zuordnungswahrscheinlichkeit berechnet. Dies kann erreicht werden, indem jeder individuelle Korrespondenzwert mit

seiner Zuordnungswahrscheinlichkeit gewichtet wird. Unter diesem Ansatz ergibt sich die Modellkorrespondenz $L(\mathcal{R} | \mathcal{C})$ kumulativ als die Summe

$$L(\mathcal{R} | \mathcal{C}) := \sum_{r_i \in \mathcal{R}} \sum_{c_j \in \mathcal{C}} p(c_j | r_i) \cdot L(r_i | c_j) \quad (7.7)$$

der gewichteten individuellen Korrespondenzwerte $L(r_i | c_j)$.

7.4.2 Individuelle Repräsentant-zu-Konzept Korrespondenz

Somit muss als nächstes die individuelle Korrespondenz eines Repräsentanten r zu einem Konzept c betrachtet werden. Ebenfalls analog zum Vorgehen bei der Komplexitätsbewertung wird hier diese individuelle Korrespondenz auf Basis der jeweiligen Attribute \mathcal{A}_r und \mathcal{A}_c bewertet. Dabei wird wiederum die Annahme getroffen, dass diese attributbasierten Korrespondenzwerte sich in Summe zur individuellen Korrespondenz von Repräsentant zu Konzept ergeben. Wenn gewünscht, kann hierbei eine unterschiedliche Gewichtung der einzelnen Attribute vorgenommen werden. Zur Berechnung der individuellen Korrespondenz wird somit für jedes Attribut $a^{r,i} \in \mathcal{A}_r$ des Repräsentanten ein attributbasierter Korrespondenzwert zum korrespondierenden Attribut $a^{c,i} \in \mathcal{A}_c$ des betrachteten Konzepts berechnet. Die Attribute $a^{r,i}$ und $a^{c,i}$ müssen dabei passend sein, d. h. dieselbe Qualität beschreiben. Die individuelle Korrespondenz zwischen Repräsentant r und Konzept c ergibt sich folglich als die gewichtete Summe

$$L(r_i | c_j) := \sum_{a^{r,i} \in \mathcal{A}_r} w_a \cdot L(a^{r,i} | a^{c,i}), \quad (7.8)$$

in welcher optional pro Attribut $a^{r,i}$ Gewichte w_a genutzt werden können. Solche Gewichte müssen ebenfalls als weitere Parameter im Domänenmodell pro Qualität spezifiziert werden.

7.4.3 Attributbasierte Korrespondenzwerte

Die attributbasierten Korrespondenzwerte $L(a^{r,i} | a^{c,i})$ stellen ein Maß dar, welches die Verteilung eines Repräsentanten-Attributs zu der eines Konzept-Attributs in Beziehung setzt. Dem MDL-Prinzip folgend, soll ein solches Maß bewerten, wie viel zusätzliche Beschreibung zur Darstellung der Verteilung des Repräsentanten-Attributs benötigt wird, wenn die Verteilung des Konzept-Attributs als Ausgangsbasis zugrunde gelegt wird. Anschaulich gesprochen wird in dieser Arbeit dabei die Annahme getroffen, dass für eine Verteilung, deren Werte vollständig in der Verteilung des Konzept-Attributs enthalten sind, keine zusätzliche Beschreibung notwendig ist. So würde z. B. für eine Gleichverteilung auf dem Intervall $[2,3]$, gegeben ein Konzept-Attribut mit ebenfalls einer Gleichverteilung, jedoch auf dem Intervall $[1,5]$, kein zusätzlicher Beschreibungsaufwand anfallen. Für eine Gleichverteilung auf dem Intervall $[0,3]$ wäre dagegen eine zusätzliche Beschreibung notwendig. Hier müsste der Bereich $[0,1]$ beschrieben werden, welcher nicht vom Konzept-Attribut abgedeckt wird. Als zugrunde liegendes Kriterium, von welchem der zusätzliche Beschreibungsaufwand abhängt, ergibt sich somit die Überlappung der betrachteten Verteilungen.

Diskrete Korrespondenzmaße

Zur Berechnung der Modellkomplexität erfolgt eine Diskretisierung von stetigen Attributen anhand des kleinsten unterscheidbaren Betrags Δ_a für solche Attribute. Für die Berechnung der attributbasierten Korrespondenzwerte kann folglich angenommen werden, dass nur diskrete Verteilungen zu betrachten sind. Als konkrete Maße zur Bewertung der Korrespondenz von diskreten Verteilungen kommen unterschiedliche Funktionen in Frage. Ein mögliches Maß, welches in der objektorientierten Umweltmodellierung z. B. bereits im Weltmodell eingesetzt wird [Bel12b], ist die Kullback-Leibler Divergenz. Die diskrete Kullback-Leibler Divergenz oder relative Entropie [Cov91] zwischen einem Repräsentanten-Attribut $a^{r,i}$ und einem

Konzept-Attribut $a^{c,i}$ ergibt sich dabei als

$$D(a^{r,i} \parallel a^{c,i}) = \sum_{a \in S_a} p_{a^{r,i}}(a) \cdot \log\left(\frac{p_{a^{r,i}}(a)}{p_{a^{c,i}}(a)}\right), \quad (7.9)$$

wobei S_a den Wertebereich des Attributs $a^{r,i}$ bezeichnet. Die relative Entropie misst, wie unterschiedlich zwei gegebene Wahrscheinlichkeitsverteilungen sind und besitzt nicht-negative Werte. Ein ähnliches Maß für die Unterschiedlichkeit zweier Wahrscheinlichkeitsverteilungen ist die Kreuzentropie. Diese ergibt sich für die Attribute $a^{r,i}$ und $a^{c,i}$ als

$$H(a^{r,i}, a^{c,i}) = \sum_{a \in S_a} p_{a^{r,i}}(a) \cdot \log(p_{a^{c,i}}(a)). \quad (7.10)$$

Weiterhin kann auch ein Maß genutzt werden, welches der oben beschriebenen Intuition der Überdeckung einer Verteilung durch eine andere Verteilung nachempfunden ist. Für eine solche diskrete, skalierte Überdeckung zwischen $a^{r,i}$ und $a^{c,i}$ wird in dieser Arbeit die Summe

$$L_o(a^{r,i}, a^{c,i}) := \sum_{a \in S_a} l_o(p_{a^{r,i}}(a), p_{a^{c,i}}(a), \eta(a^{r,i}, a^{c,i})) \quad (7.11)$$

von bedingten Differenzen

$$l_o(p_1, p_2, \eta) := \begin{cases} 0, & \text{falls } \eta \cdot p_1 \leq p_2 \\ |p_1 - p_2|, & \text{sonst} \end{cases} \quad (7.12)$$

definiert. Der Parameter η stellt dabei einen Skalierungsfaktor zwischen den Attributen dar. Dieses Maß berechnet für jeden Wert des Wertebereichs S_a die Differenz zwischen der Verteilung $p_{a^{r,i}}(a)$ des Repräsentanten-Attributs und der Verteilung $p_{a^{c,i}}(a)$ des Konzept-Attributs, falls der skalierte Wert des Repräsentanten-Attributs größer ist als der Wert des Konzept-Attributs. Dies modelliert den Fall, dass ein Wert des Repräsentanten-Attributs nicht vom Konzept-Attribut überdeckt wird. Somit fällt also zusätzlicher Beschreibungsaufwand an, welcher durch die Differenz der Werte quantifiziert wird.

Skalierung des Repräsentanten-Attributs Zur Skalierung der Werte des Repräsentanten-Attributs für den Vergleich zum Konzept-Attribut wird der Faktor $\eta(a^{r,i}, a^{c,i})$ in Abhängigkeit der Attributverteilungen berechnet. Dieser Faktor wird dabei so gewählt, dass das Maximum der Verteilung des Repräsentanten-Attributs unterhalb des kleinsten relevanten Hochpunkts als lokalem Maximum der Verteilung des Konzept-Attributs liegt. Die Idee hinter diesem heuristischen Ansatz ist, dass stetige Konzept-Attribute im Umweltmodell als Normal- oder Gaußmischverteilungen beschrieben werden, somit also potentiell multimodale Dichtefunktionen darstellen können. Zur Bestimmung der bedingten Differenzen über die Gleichungen (7.11) und (7.12) wird ein Repräsentanten-Attribut nun so skaliert, dass es unterhalb der kleinsten Komponente einer Gaußmischverteilung liegt. Diese Skalierung wird beim Vergleich der Werte der Verteilungen angewendet. Damit soll modelliert werden, dass ein Repräsentanten-Attribut durch jede Komponente einer multimodalen Mischdichte eines Konzept-Attributs beschrieben werden kann. Wird es durch mindestens eine der Komponenten beschrieben, fällt somit kein zusätzlicher Beschreibungsaufwand an. Der Skalierungsfaktor wird dabei auf den diskretisierten Verteilungen der stetigen Attribute berechnet. Auch für per se diskrete Attribute kann dieser Skalierungsansatz verwendet werden. Dazu wird zusätzlich ein Minimalwert für Hochpunkte eingeführt. Nur Hochpunkte, die größer als dieser Minimalwert sind, werden als relevant für die Skalierung betrachtet. Durch dieses Vorgehen sollen zu kleine Skalierungen verhindert werden, z. B. für nominale Attribute. Der Skalierungsansatz wurde in dieser Arbeit für das diskrete Überdeckungsmaß (7.11) entwickelt. Der Ansatz kann aber auch als ein Vorverarbeitungsschritt für andere Maße zum Vergleich von Repräsentanten-Attributen zu Konzept-Attributen bzgl. ihrer Korrespondenz genutzt werden.

Vergleich der Bewertungsmaße

Die Eigenschaften und Unterschiede der unterschiedlichen vorgestellten Maße zur Berechnung der attributbasierten Korrespondenzwerte werden

in Abschnitt 7.6 zusammen mit einer Evaluation des Gesamtansatzes der Modellbewertung vorgestellt.

7.5 Aufwandsbetrachtung

Die Gütebewertung eines Hintergrundwissensmodells über den beschriebenen Ansatz zur quantitativen Modellbewertung dient in der adaptiven Umweltmodellierung als eine übergeordnete Steuergröße. Die Güte eines Hintergrundwissensmodells muss somit in regelmäßigen Abständen bewertet werden, jedoch nicht notwendigerweise in Echtzeit (vgl. das grundlegende Verarbeitungsschema des Umweltmodells in Abschnitt 5.3.5). Zur Abschätzung des Berechnungsaufwands einer solchen Gütebewertung soll nachfolgend die Zeitkomplexität des vorgeschlagenen Ansatzes zur quantitativen Modellbewertung betrachtet werden, unterteilt in die Anteile der Modellkomplexität und der Modellkorrespondenz sowie Gemeinsames.

7.5.1 Diskretisierung stetiger Attribute

Sowohl für die Berechnung der Modellkomplexität als auch für die Berechnung der Modellkorrespondenz wird eine Diskretisierung der stetigen Attribute von Konzepten und Repräsentanten benötigt. Die Diskretisierung erfolgt dabei in Bezug auf die im Hintergrundwissen je Qualität definierten kleinsten unterscheidbaren Beträge. Im in dieser Arbeit verfolgten Ansatz zur objektorientierten Umweltmodellierung werden stetige Attribute nur parametrisch mittels Normal- oder Gaußmischverteilung dargestellt. Zur Berechnung der Wahrscheinlichkeitsmasse pro diskretem Intervall muss somit, ggf. mehrfach für unterschiedliche Komponenten einer Mischverteilung, die kumulative Verteilungsfunktion der Normalverteilung in Bezug auf das Intervall ausgewertet werden. Diese Auswertung ist auf Basis der Gauß'schen Fehlerfunktion effizient möglich. Eine endliche Anzahl an Komponenten für Mischverteilungen vorausgesetzt, kann der Zeitaufwand zur Diskretisierung eines stetigen Attributs unter diesen Bedingungen daher als linear in der Anzahl der Diskretisierungsintervalle angesehen werden.

7.5.2 Aufwandsabschätzung der Modellkomplexitätsbewertung

Zur Berechnung der Modellkomplexität muss jedes Konzept $c \in \mathcal{C}$ betrachtet werden. Pro Konzept müssen dabei alle deskriptiven Attribute $a^{c,i} \in \mathcal{A}_c$ betrachtet und bewertet werden. Zur Bewertung eines Attributs muss die Spezifität seiner Verteilung bestimmt werden. Für ein diskretes Attribut muss dabei jedes Element seines Wertebereichs S_a betrachtet werden und dessen Wahrscheinlichkeit logarithmiert, multipliziert und summiert werden. Somit ergibt sich eine Zeitkomplexität von $O(|\mathcal{C}| \cdot |\mathcal{A}_c^*| \cdot |S_a^*|)$ für die Modellbewertung. Hierbei beschreibt $|\mathcal{A}_c^*|$ analog zur Aufwandsbetrachtung für die Repräsentant-zu-Konzept Zuordnung die maximale Anzahl von deskriptiven Attributen pro Konzept und der Faktor $|S_a^*|$ die maximale Größe der Wertebereiche der diskreten oder diskretisierten Attribute. Der für die Diskretisierung der stetigen Attribute zusätzlich anfallende Diskretisierungsaufwand liegt ebenfalls in $O(|\mathcal{C}| \cdot |\mathcal{A}_c^*| \cdot |S_a^*|)$ und erhöht die Zeitkomplexität der Modellkomplexitätsbewertung somit nicht.

Weiterhin ist eine Neuberechnung der Modellkomplexität nur dann notwendig, wenn sich ein Konzept geändert hat. Auch muss in diesem Fall nur das geänderte Konzept neu bewertet sowie die Gesamtsumme aller Konzeptkomplexitätswerte neu berechnet werden.

7.5.3 Aufwandsabschätzung der Modellkorrespondenzbewertung

Zur Berechnung der Modellkorrespondenz muss bei einer probabilistischen Repräsentant-zu-Konzept Zuordnung für jeden Repräsentanten $r \in \mathcal{R}$ und jedes Konzept $c \in \mathcal{C}$ ihre Korrespondenz bewertet werden. Dazu müssen die attributbasierten Korrespondenzwerte für alle Attribute $a^{r,i} \in \mathcal{A}_r$ des Repräsentanten zu den korrespondierenden Konzept-Attributen bestimmt werden. Zur Berechnung dieser Korrespondenzwerte durch die genannten Bewertungsmaße müssen die Wahrscheinlichkeiten eines Repräsentanten-Attributs und eines Konzept-Attributs für jedes Element ihres Wertebereichs

betrachtet und verrechnet werden. Somit ergibt sich eine Zeitkomplexität von $O(|\mathcal{R}| \cdot |\mathcal{C}| \cdot |\mathcal{A}_c^*| \cdot |\mathcal{S}_a^*|)$ für die Berechnung der Modellkorrespondenz.

Der für die Diskretisierung stetiger Attribute zusätzlich anfallende Diskretisierungsaufwand von $O((|\mathcal{R}| + |\mathcal{C}|) \cdot |\mathcal{A}_c^*| \cdot |\mathcal{S}_a^*|)$ erhöht die Zeitkomplexität der Modellkorrespondenz nicht weiter. Die Wahrscheinlichkeitswerte der Repräsentant-zu-Konzept Zuordnung werden als gegeben angenommen.

Eine Neuberechnung der einzelnen Korrespondenzwerte zwischen Repräsentanten und Konzepten ist immer dann notwendig, wenn sich ein Repräsentant, ein Konzept oder deren gemeinsame Zuordnungswahrscheinlichkeit ändert. Werden pro Zeitschritt z. B. nur die (bzw. der) von einer Beobachtung betroffenen Repräsentanten aktualisiert, so müssen in der Gesamtsumme nur deren Korrespondenzwerte zu allen Konzepten neu berechnet und mit den aktualisierten Zuordnungswerten gewichtet werden.

7.6 Demonstration und Evaluation

In diesem Abschnitt wird die Evaluation und Demonstration des in dieser Arbeit entwickelten Ansatzes zur quantitativen Bewertung eines Hintergrundwissensmodells beschrieben. Ein Ziel ist es dabei, die prinzipielle Anwendbarkeit der definierten Maße für Modellkomplexität und Modellkorrespondenz zu demonstrieren. Dabei soll auch gezeigt werden, dass die Maße die für ihren Entwurf beabsichtigten Eigenschaften besitzen. Dies erfolgt in den Abschnitten 7.6.1 und 7.6.2. Dabei werden die unterschiedlichen genannten attributbasierten Korrespondenzmaße anhand eines Beispiels miteinander verglichen und in Bezug auf ihre Eigenschaften bewertet. Abschließend wird in Abschnitt 7.6.3 die quantitative Modellbewertung an einem einfachen Beispielszenario gesamthaft demonstriert. Zu diesem Zweck wird das in Abschnitt 6.3.2 definierte Demonstrationsszenario wiederverwendet. Die in diesem Kapitel dargestellten Ergebnisse wurden in [Kuw13a] veröffentlicht.

7.6.1 Modellkomplexität

Zunächst soll die Anwendbarkeit der Bewertung der Modellkomplexität demonstriert werden. Dabei stehen zwei Aspekte im Vordergrund. Einerseits soll die prinzipielle Anwendbarkeit der beiden definierten Maße $L_1(a^{c,i})$ in (7.5) und $L_2(a^{c,i})$ in (7.6) zur Bewertung der Attributkomplexität an einem Beispiel demonstriert werden. Andererseits soll gezeigt werden, dass diese Maße die beschriebene Intuition und vorgestellte Annahme über die höhere Komplexität von spezifischeren Attributverteilungen wie gewünscht umsetzen. Darüber hinaus sollen die beiden Maße auch an einem konkreten Beispiel verglichen werden.

Bewertung der Attributkomplexität

Zur Demonstration der vorgeschlagenen Bewertungsmaße für die Attributkomplexität werden ähnlich wie in Kapitel 6 einfache Konzepte aus der Haushaltsdomäne verwendet, z. B. ein *Apfel*-Konzept. Die Konzepte werden dabei wieder über ein stetiges Längenattribut und ein diskretes Farbattribut beschrieben. Zusätzlich zum *Apfel*-Konzept wird ein allgemeineres Konzept betrachtet. Dieses Konzept könnte dem *Apfel*-Konzept in einer „is-a“-Hierarchie als Vaterkonzept übergeordnet sein. Es ergibt sich hier konkret als die Summe aus dem *Apfel*-Konzept und einem *Kokosnuss*-Konzept und wird daher als *Apfel-Kokosnuss* bezeichnet. Tabelle 7.1 stellt die Definitionen dieser Konzepte dar. Der Wertebereich des Farbattributs besteht dabei aus den sieben Symbolen *w* (weiß), *b* (blau), *gr* (grün), *ge* (gelb), *o* (orange), *r* (rot) und *br* (braun). In der Tabelle sind jeweils nur die Farbwerte angegeben, welche eine von 0 verschiedene Wahrscheinlichkeit besitzen.

Tabelle 7.1: Beispielhafte Konzepte mit zwei Attributen zur Evaluation der Bewertungsmaße für die Konzeptkomplexität.


Konzept	Länge/cm	Farbe
Apfel	$\mathcal{N}(7, 1^2)$	r: 0.50, gr: 0.30, ge: 0.2
Apfel-Kok.	$(\mathcal{N}(7, 1^2) + \mathcal{N}(18, 4^2)) / 2$	r: 0.25, gr: 0.15, ge: 0.1, br: 0.5

Die Ergebnisse der Anwendung der Bewertungsmaße für die Attributkomplexität sind in Tabelle 7.2 dargestellt. Zum Vergleich ist für jedes Attribut ebenfalls die Entropie $H(\cdot)$ der Attributverteilung dargestellt. Die Ergebnisse für das stetige Längenattribut basieren auf einer vorherigen Diskretisierung seiner Wahrscheinlichkeitsverteilung, wie in Abbildung 7.1 illustriert. Als kleinster unterscheidbarer Betrag wurde hier ein Wert von $\Delta = 1$ cm verwendet mit einem Wertebereich von 0–50 cm.


Tabelle 7.2: Ergebnisse der Bewertung der Attributkomplexität durch die beiden vorgeschlagenen Bewertungsmaße für die diskreten und stetigen Attribute aus Tabelle 7.1.

Attribut $\mathbf{a}^{c,i}$	$L_1(\mathbf{a}^{c,i})$	$L_2(\mathbf{a}^{c,i})$	$H(\mathbf{a}^{c,i})$
Farbe (Apfel)	0.92	0.47	1.03
Farbe (Apfel-Kokos.)	0.74	0.38	1.21
Länge $^{\Delta=1 \text{ cm}}$ (Apfel)	2.45	0.63	1.46
Länge $^{\Delta=1 \text{ cm}}$ (Apfel-Kokos.)	1.13	0.29	2.78

Anhand der Ergebnisse wird deutlich, dass die vorgeschlagenen Bewertungsmaße anwendbar sind. Für das Bewertungsmaß $L_2(\cdot)$ ergeben sich wie gewünscht auf das Intervall $[0,1]$ skalierte Werte. Das Bewertungsmaß $L_1(\cdot)$ ist dagegen unbeschränkt. Die Werte für das diskrete Farbattribut und das diskretisierte stetige Längenattribut liegen dabei in der gleichen Größenordnung. Wichtig ist die Tatsache, dass die Werte der Bewertungsmaße für das spezifischere *Apfel*-Konzept für beide Attribute höher ausfallen als die Werte



(a) Stetige Verteilung



(b) Diskretisierte Verteilung

Abbildung 7.1: Beispiel für die Diskretisierung eines stetigen Attributs unter Verwendung eines kleinsten unterscheidbaren Betrags Δ . Dargestellt ist das Längenattribut des *Apfel-Kokosnuss*-Konzepts aus Tabelle 7.1 und seine Diskretisierung mit $\Delta = 1$ cm.

für das allgemeinere, weniger spezifische *Apfel-Kokosnuss*-Konzept. Die vorgeschlagenen Maße entsprechen somit wie beabsichtigt der beschriebenen Intuition, dass spezifischere Attribute als komplexer zu bewerten sind.

Bewertung der Konzeptkomplexität


Für die beiden betrachteten Konzepte ergeben sich unter Anwendung des attributbasierten Komplexitätsmaßes $L_1(\cdot)$ die folgenden Komplexitätswerte: Das *Apfel*-Konzept besitzt eine Komplexität von $L(\text{Apfel}) = 3.37$, das *Apfel-Kokosnuss*-Konzept eine Komplexität von $L(\text{Apfel-Kokosnuss}) = 1.87$. Auch hier wird die höhere Komplexität des *Apfel*-Konzepts deutlich.

7.6.2 Modellkorrespondenz


Nach der Modellkomplexität wird nun die Modellkorrespondenz betrachtet. Auch hier soll die prinzipielle Anwendbarkeit des entwickelten Ansatzes demonstriert werden. Weiterhin sollen Maße zur Bewertung der Attributkorrespondenz evaluiert und verglichen werden, darunter die relative Entropie (KL Divergenz), die Kreuzentropie sowie das vorgeschlagene diskrete skalierte Überdeckungsmaß (7.11). Bei der Evaluation dieser Maße ist auch die Frage wichtig, wie sehr die Maße zur Quantifizierung des zusätzlichen Beschreibungsaufwands geeignet sind, welcher benötigt wird, um ein Repräsentanten-Attribut zu beschreiben, wenn ein Konzept-Attribut als Modell gegeben ist.

Vergleich und Evaluation der attributbasierten Korrespondenzmaße

In Abbildung 7.3 sind Ergebnisse für die Evaluation der betrachteten attributbasierten Korrespondenzmaße dargestellt. Die drei gezeigten Maße wurden dabei auf ein gegebenes diskretes Konzept-Attribut und ein variabel positioniertes diskretes Repräsentanten-Attribut angewendet. Die Verteilung des Konzept-Attributs ist in Abbildung 7.2a dargestellt, die des Repräsentanten-Attributs in Abbildung 7.2b. Zur Evaluation wird die




(a) Beispielhaftes diskretes Konzept-Attribut




(b) Beispielhaftes diskretes Repräsentanten-Attribut


Abbildung 7.2: Zur Evaluation der attributbasierten Korrespondenzmaße genutzte Verteilungen. Die Verteilung des Repräsentanten-Attributs wird dabei Schritt für Schritt nach rechts durch ihren Wertebereich verschoben.



(a) Relative Entropie (KL Div.)



(b) Kreuzentropie



(c) Diskrete Überdeckung

Abbildung 7.3: Vergleich von drei attributbasierten Korrespondenzmaßen. Die Werte der Korrespondenzmaße in den drei Teilabbildungen werden jeweils für die beiden in Abbildung 7.2 dargestellten Attribute berechnet, wobei die Verteilung des Repräsentanten-Attributs in 7.2b bei der Berechnung über seinen Wertebereich nach rechts verschoben wird. Auf der x-Achse der drei Teilabbildungen ist daher die aktuelle Verschiebung des Repräsentanten-Attributs dargestellt, die y-Achse beschreibt jeweils den Wert der relativen Entropie (a), Kreuzentropie (b) bzw. des diskreten skalierten Überdeckungsmaßes (c) für die aktuelle Konstellation der Attribute.

Verteilung des Repräsentanten-Attributs variiert, indem sie von links nach rechts durch den dargestellten Wertebereich verschoben wird. Für jede Verschiebung wird jeweils der Korrespondenzwert zum Konzept-Attribut ermittelt, mit allen drei genannten Bewertungsmaßen.

Die jeweiligen Korrespondenzwerte für diese Verschiebung sind in den Abbildungen 7.3a, 7.3b und 7.3c dargestellt. Die x-Achse der einzelnen Abbildungen beschreibt dabei die Verschiebung des Repräsentanten-Attributs, welche der Berechnung zugrunde lag. Ein Verschiebungswert von z. B. $x = 5$ ist dabei so zu interpretieren, dass das Repräsentanten-Attribut auf die Position $x_r = 5$ seines Wertebereichs (in Abbildung 7.2b) verschoben wurde, und zwar derart, dass der erste von 0 verschiedene Wert auf $x_r = 5$ liegt und der in diesem Fall mittig gelegene Modalwert der Verteilung auf $x_r = 6$. Für einen Verschiebungswert von 8 liegen somit die Modalwerte der Verteilungen von Konzept-Attribut und Repräsentanten-Attribut auf derselben Position $x_r = 9$ im Wertebereich der Attribute. Die einzelnen Abbildungen stellen die Bewertungsergebnisse für die Attributkorrespondenz durch die Maße relative Entropie $D(\cdot || \cdot)$ in 7.3a, Kreuzentropie $H(\cdot, \cdot)$ in 7.3b und das diskrete skalierte Überdeckungsmaß $L_o(\cdot, \cdot)$ in 7.3c dar.

Anhand dieser Abbildungen ist zunächst erkennbar, dass alle drei Maße prinzipiell geeignet sind, um eine attributbasierte Korrespondenz, und somit die zusätzlich notwendige Beschreibungslänge für das Repräsentanten-Attribut unter Verwendung des Konzept-Attributs als Modell, zu bewerten. Im Detail fallen die Bewertung jedoch unterschiedlich aus in Bezug auf zwei Aspekte. Einerseits unterscheiden sich die Größen der Korrespondenzwerte. Für das diskrete skalierte Überdeckungsmaß sind die Korrespondenzwerte dabei auf das Intervall $[0,1]$ beschränkt, für die anderen beiden Maße ist dies nicht der Fall. Der Maximalwert von 1 ergibt sich für das Überdeckungsmaß für den Fall, dass beide Attributverteilungen sich nicht überlappen. Die Summe der Differenzen in (7.11) und (7.12) gleicht in diesem Fall der Summe über die Verteilung des Repräsentanten-Attributs und ergibt somit den Wert 1. Das Überdeckungsmaß ist weiterhin das einzige der drei Maße, dass die zusätzlich notwendige Beschreibungslänge mit 0 bewertet für den Fall, dass das Konzept-Attribut das skalierte Repräsentanten-Attribut

komplett überdeckt (Verschiebungswert $x = 8$). Dies liegt in der Skalierung des Repräsentanten-Attributs begründet. Die relative Entropie erreicht für diesen Fall einen Wert nahe 0. Beide Maße setzen in diesem Fall und auch insgesamt die der Attributkorrespondenz zugrunde liegende Intuition einer zusätzlich notwendigen Beschreibungslänge hinreichend gut um. Weiterhin ist festzustellen, dass relative Entropie und Kreuzentropie einen glatteren Verlauf darstellen, wenn man die sich für jede Verschiebung ergebenden Korrespondenzwerte zur einer Kurve verbindet.

Kombination mit Komplexitätsmaßen

Als Ergebnis dieser Evaluation lässt sich insgesamt festhalten, dass sowohl die relative Entropie als auch das diskrete skalierte Überdeckungsmaß zwei geeignete Bewertungsmaße für die Attributkorrespondenz darstellen. Zur Gesamtbewertung der Qualität eines Modells müssen die Korrespondenzmaße mit den zuvor betrachteten Komplexitätsmaßen kombiniert werden. Hier eignet sich die relative Entropie als attributbasiertes Korrespondenzmaß gut, um zusammen mit dem unbeschränkten attributbasierten Komplexitätsmaß $L_1(\cdot)$ eingesetzt zu werden. Das diskrete skalierte Überdeckungsmaß eignet sich aufgrund seines beschränkten Wertebereichs dagegen gut, um zusammen mit dem normalisierten attributbasierten Komplexitätsmaß $L_2(\cdot)$ eingesetzt zu werden.

7.6.3 Evaluation an einem einfachen Beispielszenario

Nach der individuellen Betrachtung der Bewertungsmaße für Modellkomplexität und Modellkorrespondenz sowie der Demonstration ihrer grundsätzlichen Anwendbarkeit soll der Ansatz der quantitativen Modellbewertung ganzheitlich anhand eines Beispielszenarios demonstriert und evaluiert werden. Zu diesem Zweck wird das bereits in Abschnitt 6.3.2 vorgestellte einfache Demonstrationsszenario aus dem Bereich der Haushaltsdomäne wiederverwendet. Als Hintergrundwissen dient daher wieder die Menge der Konzepte $\mathcal{C} = \{\text{Apfel}, \text{Banane}, \text{Kokosnuss}\}$. Diese Konzepte wurden in Tabelle

6.1 definiert. Der Übersicht halber werden die Attributwerte dieser Konzepte in Tabelle 7.3 nochmals zusammengefasst. Jedes der Konzepte wird dabei über ein diskretes Farbattribut und ein stetiges Längenattribut beschrieben.

Für die Demonstration der quantitativen Modellbewertung wird ein sich zeitlich ändernder Inhalt des Weltmodells angenommen. Im Demonstrationsszenario werden daher zu verschiedenen Zeitpunkten unterschiedliche Entitäten in der Umgebung beobachtet, welche dann in Form von Repräsentanten im Weltmodell dargestellt werden. Im Szenario werden dabei nur diejenigen Zeitschritte betrachtet, in denen neue Repräsentanten ins Weltmodell aufgenommen werden. Dabei wird zu Demonstrationszwecken vereinfachend angenommen, dass Beobachtungen zu anderen Zeitpunkten keine für die Modellbewertung relevanten Änderungen an den Repräsentanten bewirken. Beispielsweise können Beobachtungen zu solchen Zeitpunkten nur Änderungen an den zustandsbezogenen Attributen beobachteter Repräsentanten betreffen. Die Repräsentanten des Szenarios entsprechen den in Tabelle 6.2 für das einfache Demonstrationsszenario definierten Repräsentanten. Der Übersicht halber werden auch die Repräsentanten nochmals in Tabelle 7.4 zusammengefasst. Weiterhin wird für jeden Repräsentanten auch der Zeitpunkt im Szenario angegeben, zu welchem dieser dem Weltmodell hinzugefügt wird. Die Reihenfolge der Repräsentanten in der Tabelle entspricht dabei der Reihenfolge ihres Auftretens im Szenario.

Tabelle 7.3: Konzepte im Hintergrundwissen \mathcal{C} im einfachen Demonstrationsszenario (Zusammenfassung von Tabelle 6.1).

Name	Länge/cm	Farbe
<i>Apfel</i>	$\mathcal{N}(9, 1^2)$	grün-gelb-rot (3:2:5)
<i>Banane</i>	$\mathcal{N}(18, 2^2)$	grün-gelb-braun (1:5:1)
<i>Kokosnuss</i>	$\mathcal{N}(16, 1.5^2)$	braun

Tabelle 7.4: Im Demonstrationsszenario betrachtete Repräsentanten in der Reihenfolge und mit dem Zeitpunkt ihres Auftretens. Die Repräsentanten werden dabei über ein stetiges Längenattribut sowie ein diskretes Farbattribut beschrieben (Erweiterung zu Tabelle 6.2).

Name	Länge/cm	Farbe	Zeit
<i>Apfel1</i>	$\mathcal{N}(8, 0.5^2)$	grün-gelb (1:1)	2
<i>Apfel2</i>	$\mathcal{N}(7, 0.2^2)$	rot	3
<i>Kokosnuss1</i>	$\mathcal{N}(15, 0.75^2)$	braun	4
<i>Birne1</i>	$\mathcal{N}(13, 0.2^2)$	grün-gelb (3:1)	5
<i>Erdbeere1</i>	$\mathcal{N}(3.5, 1^2)$	rot	6

Die Ergebnisse der quantitativen Modellbewertung in diesem Demonstrationsszenario sind in Abbildung 7.4 dargestellt. Dabei wird sowohl das Gesamtmaß für die Modellgüte $Q(\mathcal{R}, \mathcal{C})$ als auch der reine Anteil der Modellkorrespondenz $L(\mathcal{R} | \mathcal{C})$ gezeigt. Die Modellkomplexität $L(\mathcal{C})$ ergibt sich indirekt als Differenz der beiden Maße. Zur Interpretation der gezeigten Verläufe ist anzumerken, dass die Modellgüte nach dem gewählten MDL-basierten Ansatz in Form einer Beschreibungslänge dargestellt wird. Je größer diese Beschreibungslänge ist, desto geringer ist die Qualität des Modells. Kleinere Werte für die Modellgüte $Q(\mathcal{R}, \mathcal{C})$ sind somit erstrebenswert, da sie eine bessere Qualität beschreiben.

Das betrachtete Demonstrationsszenario läuft wie nachfolgend beschrieben ab. Im ersten Schritt des Szenarios ($k = 1$) ist noch kein Repräsentant im Weltmodell enthalten. Der gezeigte Wert des Gesamtmaßes für die Modellgüte entspricht in diesem Zeitschritt somit der Modellkomplexität, d. h. der kumulierten Komplexität der drei Konzepte *Apfel*, *Banane* und *Kokosnuss*. In den nächsten zwei Zeitschritten ($k = 2$ und $k = 3$) wird jeweils ein Apfel-Repräsentant dem Weltmodell hinzugefügt (*Apfel1*, *Apfel2*), und danach ($k = 4$) ein Kokosnuss-Repräsentant (*Kokosnuss1*). Das moderate Ansteigen der Bewertungsmaße mit dem Korrespondenzwert repräsentiert in diesen Schritten daher die pro Repräsentant über das Hintergrundwissen hinausgehend notwendige Beschreibungslänge. In den Zeitschritten $k = 5$ und $k = 6$ werden Repräsentanten zum Weltmodell hinzugefügt, für welche




Abbildung 7.4: Entwicklung zweier Bewertungsmaße der quantitativen Modellbewertung im betrachteten einfachen Demonstrationsszenario über sieben Zeitschritte. Kleinere Werte für die gezeigte Gesamtgüte $Q(\mathcal{R}, \mathcal{C})$ eines Modells stellen dabei eine bessere Modellqualität dar. Als ein Anteil der Modellgüte beschreibt die Modellkorrespondenz $L(\mathcal{R} | \mathcal{C})$, wie viel zusätzlicher Beschreibungsaufwand notwendig ist, um die Repräsentanten im Weltmodell darstellen zu können, wenn als Modell die Konzepte des Hintergrundwissens genutzt werden. In den Zeitschritten 2–6 wird jeweils ein neuer Repräsentant aus Tabelle 7.4 ins Weltmodell eingefügt. Für die in den Zeitschritten 5–6 eingefügten Repräsentanten sind dabei keine Konzepte im Hintergrundwissen enthalten, daher steigen die Werte der Bewertungsmaße stärker an. Zeitschritt 7 demonstriert, wie das Hinzufügen eines neuen Konzepts zu einer Verbesserung der Modellgüte über eine verbesserte Modellkorrespondenz führen kann.

keine passenden Konzepte im Hintergrundwissen modelliert sind: eine Birne (*Birne1*) und einer Erdbeere (*Erdbeere1*). Dies führt jeweils zu einer deutlichen Verschlechterung der Modellqualität durch die nun zusätzlich notwendige Beschreibung, dargestellt über den jeweiligen Korrespondenzwert.

Die Modellqualität kann verbessert werden, wenn für die bisher nur schlecht beschriebenen Repräsentanten neue Konzepte erzeugt und dem Hintergrundwissen hinzugefügt werden. Dies wird im letzten Zeitschritt ($k = 7$) des Demonstrationsszenarios simuliert, indem die Menge \mathcal{C} um ein Konzept *Birne* erweitert wird. Dies führt zu einem reduzierten Korrespondenzwert und somit zu einer verbesserten Modellqualität. Die Modellqualität verbessert sich allerdings nicht im gleichen Umfang wie der Korrespondenzwert, da in die Berechnung der Modellgüte zusätzlich noch die Modellkomplexität

mit eingeht. Das Hinzufügen eines neuen Konzepts zum Hintergrundwissen führt zu einer erhöhten Modellkomplexität.

Die Berechnung der Bewertungsmaße im Demonstrationsszenario erfolgt unter Verwendung des attributbasierten Komplexitätsmaßes $L_1(a_d^c)$ (7.5) für die Modellkomplexität. Das stetige Längenattribut wird dabei unter Verwendung eines kleinsten unterscheidbaren Betrags $\Delta = 1$ cm und für einen Wertebereich von 0–50 cm diskretisiert. Die Berechnung der Modellkorrespondenz erfolgt unter Verwendung der diskreten relativen Entropie als attributbasiertes Korrespondenzmaß. Als Vorverarbeitungsschritt wird dabei das jeweilige Repräsentanten-Attribut über den für das diskrete Überdeckungsmaß beschriebenen Skalierungsansatz mit dem Faktor $\eta(a^{r,i}, a^{c,i})$ (vgl. (7.11)) multipliziert. Für die Berechnung der erwarteten Konzeptkorrespondenz wird eine probabilistische Repräsentant-zu-Konzept Zuordnung nach Gleichung (6.7) verwendet. Die sich ergebenden Zuordnungswahrscheinlichkeiten für die betrachteten Repräsentanten sind dabei bereits als Ergebnisse in Kapitel 6 dargestellt (mit Ausnahme des Repräsentanten *Apfel2*, für welchen sich eine Zuordnung zum Konzept *Apfel* ergibt).

7.7 Zusammenfassung

In diesem Kapitel wurde ein Ansatz zur quantitativen Bewertung eines Hintergrundwissensmodells vorgestellt. Ein solche Bewertung ist dabei eine wichtige Aufgabe innerhalb der adaptiven Umweltmodellierung. Die aktuelle Güte eines Hintergrundwissensmodells kann dabei im Speziellen als eine übergeordnete Steuergröße für die adaptive Wissensverwaltung dienen.

Der vorgestellte Ansatz zur quantitativen Modellbewertung basiert auf dem Prinzip der minimalen Beschreibungslänge als Informationskriterium und besteht aus zwei Anteilen. Dabei wird als erster Anteil zunächst die Komplexität eines Modells bewertet. Zu diesem Zweck wurde ein kumulierendes Maß über den Konzepten des Hintergrundwissensmodells definiert. In diesem Maß wird die Komplexität eines Konzepts als eine Summe über

der Spezifität seiner Attribute berechnet. Die Spezifität einer Attributverteilung ergibt sich unter Verwendung der Shannon'schen Entropie. Neben der Komplexität wird als zweiter Anteil die Korrespondenz der Repräsentanten des Weltmodells zu den modellierten Konzepten im Hintergrundwissen bewertet. Auch zu diesem Zweck wurde ein kumulierendes Maß definiert. Als Basisgröße der Bewertung wird hier die Korrespondenz zwischen einem Repräsentanten-Attribut und dem korrespondierenden Konzept-Attribut betrachtet. Diese Korrespondenz wird durch einen Vergleich ihrer Attributverteilungen bewertet. Ein Bewertungsmaß beschreibt in diesem Fall, wie viel zusätzliche Beschreibung zur Darstellung der Verteilung des Repräsentanten-Attributs notwendig ist, wenn das korrespondierende Konzept-Attribut als Modell zugrunde gelegt wird. Als ein solches Bewertungsmaß kann z. B. die relative Entropie eingesetzt werden.

Die für die quantitative Modellbewertung definierten und vorgeschlagenen Bewertungsmaße wurden anschließend anhand von ausgewählten Beispielen in ihrer prinzipiellen Anwendbarkeit evaluiert und demonstriert. Ebenfalls wurde eine gesamthafte Evaluation des Ansatzes an einem einfachen Beispielszenario durchgeführt und beschrieben.

8 Adaptive Verwaltung von Hintergrundwissensmodellen

8.1 Überblick

In Abschnitt 3.2.2 wurden die Teilaufgaben der adaptiven Umweltmodellierung im Überblick genannt. Eine wichtige Teilaufgabe ist dabei die quantitative Modellbewertung, für welche in Kapitel 7 entsprechende Maße vorgestellt wurden. Die quantitative Modellbewertung ermöglicht es, eine abnehmende Modellgüte und somit zugleich den Bedarf für eine Modellanpassung festzustellen. Die Durchführung einer solchen Modellanpassung fällt in den Aufgabenbereich der adaptiven Modellverwaltung. Die adaptive Modellverwaltung stellt dabei das Analogon der Hintergrundwissens-Komponente zur Informationsverwaltung in der Weltmodell-Komponente dar. In der adaptiven Modellverwaltung werden alle Aufgaben zusammengefasst, welche dazu dienen, ein Hintergrundwissensmodell bei abnehmender Güte in Bezug auf die in der Umgebung beobachtete Situation adaptiv zu verbessern. Sie stellt somit einen Gesamtansatz zur Umsetzung der bisher für die adaptive Umweltmodellierung beschriebenen Konzepte dar. Analog zur Informationsverwaltung im Weltmodell zeichnet sich die adaptive Wissensverwaltung durch ein übergeordnetes Verarbeitungsschema aus, nach welchem solche Modellanpassungen für ein objektorientiertes Umweltmodell durchgeführt werden. Methodisch baut die adaptive Modellverwaltung auf der quantitativen Modellbewertung auf, indem zur Durchführung ihrer Aufgaben die dort definierten Bewertungsmaße genutzt werden, sowie auf der in Kapitel 6 beschriebenen Repräsentant-zu-Konzept Zuordnung.

Eine der Aufgaben der adaptiven Modellverwaltung ist es, die Datengrundlage bereitzustellen, auf welcher Modellanpassungen erfolgen können. Dazu müssen Repräsentanten im Weltmodell detektiert und identifiziert werden, welche nur schlecht von den bisher im Hintergrundwissen enthaltenen Konzepten beschrieben werden. Zu diesem Zweck nutzt die adaptive Modellverwaltung Detektionsmaße, welche in Abschnitt 8.2 beschrieben werden. Die Darstellungen basieren dabei auf [Kuw13b], wenn nicht anders angegeben. Da Modellanpassungen in der adaptiven Umweltmodellierung prinzipiell bedarfsgerecht und relevanzbezogen erfolgen, ist eine bloße Detektion von schlecht beschriebenen Repräsentanten in einem Zeitschritt nicht ausreichend. In der objektorientierten Umweltmodellierung wird pro Zeitschritt die Beobachtung einer Entität der Umgebung verarbeitet (vgl. Abschnitt 5.1.1). Somit kann pro Zeitschritt maximal ein neuer Repräsentant ins Weltmodell aufgenommen werden und ggf. einen schlecht beschriebenen Repräsentanten darstellen. Für die adaptive Umweltmodellierung wird daher die Annahme getroffen, dass die Relevanz einer Entität bzw. eines Typs von Entität für das objektorientierte Umweltmodell mit der Häufigkeit ihres Auftretens korreliert. Ist ein Objekt beispielsweise für eine Aufgabe des kognitiven Systems relevant, so wird es häufig von diesem beobachtet werden, um z. B. mehr oder aktuellere Informationen über das Objekt erwerben zu können. Somit stellt ein solches Objekt häufig das in einem Zeitschritt beobachtete Objekt dar. Um diesen Annahmen entsprechend die Relevanz von angetroffenen schlecht beschriebenen Repräsentanten beurteilen zu können, muss somit über ihr Auftreten im Verlauf der Zeit Buch geführt werden. Eine solche Verwaltung von schlecht beschriebenen Repräsentanten wird im Rahmen von Abschnitt 8.3 vorgestellt.

Wird durch eine übergeordnete Bewertung der Bedarf für eine Modellanpassung festgestellt, so muss als nächstes der Ausgangspunkt für eine solche Anpassung bestimmt werden. Dazu werden die verwalteten schlecht beschriebenen Repräsentanten betrachtet und untersucht. Ziel dieser Untersuchung ist es, eine Menge von relevanten Repräsentanten zu identifizieren, welche zu einer möglichst großen Verbesserung der Modellgüte führt, wenn die enthaltenen Repräsentanten als Lernbeispiele für ein neues, dem Modell hinzuzufügendes Konzept dienen. Das Vorgehen zur Auswahl einer solchen

Menge von schlecht beschriebenen Repräsentanten als Lernbeispiele wird in Abschnitt 8.3.2 beschrieben. Ist eine Menge von Lernbeispielen gegeben, so können Modellanpassungen durchgeführt werden. Dazu muss zunächst entschieden werden, ob ein gänzlich neues Konzept gelernt oder ein existierendes Konzept angepasst werden soll. Anschließend können die entsprechenden Modellanpassungen durchgeführt werden. Diese Aspekte werden in den Abschnitten 8.3.3 und 8.4 beschrieben. Bevor neue Änderungen in ein Hintergrundwissensmodell übernommen werden, wird zunächst durch die quantitative Modellbewertung die Güte des geänderten Modells vorhergesagt. Verbessert sich durch die Anpassung die Modellgüte, so wird diese Anpassung ins Hintergrundwissen übernommen.

Das Verarbeitungsschema, welches den eben genannten Schritten zugrunde liegt, wird in Abschnitt 8.3.1 vorgestellt. Zur Demonstration und Evaluation des vorgestellten Ansatzes der adaptiven Wissensverwaltung sowie der Anteile der adaptiven Umweltmodellierung insgesamt wird in Abschnitt 8.5 schließlich ein komplexeres Anwendungsszenario betrachtet. Für dieses Szenario werden probabilistische Konzepte definiert.

8.2 Detektion von schlecht beschriebenen Repräsentanten

Ist die anhand der quantitativen Modellbewertung bestimmte Güte eines Hintergrundwissensmodells nicht ausreichend für das objektorientierte Umweltmodell, so bedeutet dies zugleich, dass im Weltmodell Repräsentanten vorhanden sein müssen, welche nicht ausreichend gut durch die Konzepte des Hintergrundwissens beschrieben werden. Solche schlecht beschriebenen Repräsentanten müssen nun durch eine Modellanpassung adressiert werden. Sie stellen somit den Ausgangspunkt von Modellanpassungen dar. Daher ist es für eine adaptive Umweltmodellierung notwendig, solche Repräsentanten im Weltmodell zu identifizieren bzw. zu detektieren.

Zur Detektion müssen das Weltmodell bzw. ein spezifischer Repräsentant sowie die Konzepte des Hintergrundwissens betrachtet und verglichen werden. Ein solcher Vergleich sollte auch berücksichtigen, zu welchem Zweck und auf welche Weise die modellierten Konzepte in der objektorientierten Umweltmodellierung genutzt werden, wie z. B. zur semantischen Vervollständigung von Repräsentanten. Ein nahe liegendes Vorgehen ist es daher, diesen Vergleich auf Basis der bisher genutzten Maße vorzunehmen, z. B.

- der Repräsentant-zu-Konzept Zuordnung oder
- der Korrespondenzmaße der quantitativen Modellbewertung.

Dabei lassen sich grundsätzlich zwei Arten von Ansätzen unterscheiden. Globale Ansätze wie die quantitative Modellbewertung betrachten und bewerten dabei alle Repräsentanten des Weltmodells kumulativ. Weiterhin können hier auch unterschiedliche Zustände des Weltmodells über die Zeit betrachtet werden, unter Verwendung der gespeicherten Historie. Lokale Ansätze berücksichtigen dagegen immer nur den aktuellen Zeitpunkt und betrachten jeden Repräsentanten individuell.

8.2.1 Globale Ansätze zur Detektion

Ein erster Ansatz, um schlecht beschriebene Repräsentanten zu erkennen, basiert auf der Gütebewertung des Gesamtmodells in Verbindung mit der Annahme, dass im objektorientierten Umweltmodell in jedem Zeitschritt nur maximal ein neuer Repräsentant ins Weltmodell aufgenommen werden kann. Ändert sich somit in einem Zeitschritt, in welchem ein neuer Repräsentant ins Weltmodell aufgenommen wird, die Gesamtgüte des Modells maßgeblich, so kann dies dem neu erzeugten Repräsentanten zugeschrieben werden. Unter dieser Annahme können dann die Maße der quantitativen Modellbewertung als globale Detektionsmaße für schlecht beschriebene Repräsentanten eingesetzt werden. Hierbei ist allerdings nur der Anteil der Modellkorrespondenz $L(\mathcal{R} | \mathcal{C})$ am Gesamtmaß relevant, da die Modellkomplexität rein die Konzepte betrachtet.

Ein allgemeiner Ansatz für ein solch globales, korrespondenzbasiertes Detektionsmaß $M_g(\cdot)$ für den Zeitpunkt t_n kann also als

$$M_g(\mathcal{R}_{0:n}, \mathcal{C}) := g\left(L(\mathcal{R}_{t_0} | \mathcal{C}), L(\mathcal{R}_{t_1} | \mathcal{C}), \dots, L(\mathcal{R}_{t_n} | \mathcal{C})\right) \quad (8.1)$$

formuliert werden, wobei $g(\cdot)$ eine aggregierende Funktion über die Modellkorrespondenzwerte der einzelnen Zeitpunkte t_0, t_1, \dots, t_n darstellt.

Als ein einfaches Detektionsmaß kann die Änderung der Modellkorrespondenz von einem Zeitschritt auf den nächsten betrachtet werden. Hierzu kann die Aggregationsfunktion $g_1^a(\cdot)$ definiert werden als

$$g_1^a(\cdot) := L(\mathcal{R}_{t_n} | \mathcal{C}) - L(\mathcal{R}_{t_{n-1}} | \mathcal{C}) . \quad (8.2)$$

Diese Funktion beschreibt die absolute Änderung des Modellkorrespondenzmaßes (d. h. der notwendigen Beschreibungslänge) für die im aktuellen Zeitschritt beobachtete Entität. Wird ein neuer Repräsentant dem Weltmodell hinzugefügt, so steigt der Wert des Modellkorrespondenzmaßes an. Für aktualisierte Repräsentanten kann der Wert auch sinken. Die Grundannahme bei diesem Maß ist, dass für einen schlecht beschriebenen neuen Repräsentanten ein größerer Anstieg stattfindet und dies über einen Schwellwert detektiert werden kann. Die Größe eines solchen Schwellwerts festzulegen, ist allerdings nicht einfach, da die Werte der Korrespondenzmaße von den konkreten Attributen eines Anwendungsfalls abhängen. Dies betrifft die Anzahl, Wertebereiche sowie die mögliche Diskretisierung der Attribute.

Um die Definition eines solchen Schwellwerts zu vereinfachen, können weitere Annahmen getroffen werden. So kann z. B. angenommen werden, dass ein a priori erstelltes Wissensmodell im Regelfall die in der Umgebung beobachteten Entitäten beschreiben kann und schlecht beschriebene Repräsentanten nur die Ausnahme darstellen. Unter dieser Annahme lässt sich die erwartete Zunahme der Modellkorrespondenz pro Zeitschritt für den Fall bestimmen, dass kein schlecht beschriebener Repräsentant auftritt. Dies kann z. B. approximativ durch eine Mittelung der Änderungswerte über die bisherige Betriebszeit des Umweltmodells erfolgen. Diese erwartete Zunahme kann nun als Ausgangspunkt für die Definition eines Schwellwerts genutzt

werden. Somit lässt sich ein zweites Detektionsmaß als

$$g^r(\cdot) := \left(L(\mathcal{R}_{t_n} | \mathcal{C}) - L(\mathcal{R}_{t_{n-1}} | \mathcal{C}) \right) - \frac{\sum_{r=1}^{n-1} L(\mathcal{R}_{t_r} | \mathcal{C}) - L(\mathcal{R}_{t_{r-1}} | \mathcal{C})}{n-1} \quad (8.3)$$

definieren, welches die relative Änderung des Korrespondenzwerts im aktuellen Zeitschritt gegenüber der bisherigen mittleren Änderung der Korrespondenzwerte pro Zeitschritt bewertet. Für dieses Maß kann ein Schwellwert zur Detektion dann z. B. auf Basis der mittleren Änderung pro Zeitschritt definiert werden.

8.2.2 Lokale Ansätze zur Detektion

Als eine Alternative zu Maßen, welche kumulativ alle Repräsentanten des Weltmodells betrachten, können auch lokale Detektionsmaße genutzt werden. Ein lokales Detektionsmaß betrachtet dabei pro Zeitschritt jeweils nur den oder die Repräsentanten, welche in diesem Zeitschritt aktualisiert wurden. Auch zur Definition eines lokalen Detektionsmaßes kann auf den bereits vorgestellten Maßen aufgesetzt werden. Zu diesem Zweck kann z. B. die Konzeptkorrespondenz eines Repräsentanten zu den Konzepten $c \in \mathcal{C}$ genutzt werden.

Korrespondenzbasiertes Detektionsmaß

Unter Verwendung eines skalierten Bewertungsmaßes für die Attributkorrespondenz ergibt sich eine Korrespondenz von 0 oder nahe daran für einen Repräsentanten, welcher durch ein Konzept gut beschrieben wird. Ergibt sich dagegen über alle Konzepte hinweg kein solcher Wert, so ist der Repräsentant schlecht beschrieben. Um das Vorliegen eines solchen Werts bewerten zu können, muss ebenfalls ein Schwellwert definiert werden. In Abbildung 8.1 sind beispielhaft die Korrespondenzwerte von drei Repräsentanten zu den Konzepten *Apfel*, *Banane* und *Kokosnuss*, wie in Abschnitt 6.3.2




Abbildung 8.1: Beispielwerte für die Konzeptkorrespondenz für drei Repräsentanten zur Konzeptmenge $\mathcal{C} = \{\text{Apfel}, \text{Banane}, \text{Kokosnus}\}$ wie in Abschnitt 6.3.2 definiert. Ein Korrespondenzwert von nahe 0 für zumindest eines der Konzepte stellt dabei einen gut beschriebenen Repräsentanten dar, wie in den rechten beiden Teilabbildungen (b) und (c) gezeigt. Liegt dagegen kein solcher Wert vor, handelt es sich um einen schlecht beschriebenen Repräsentanten, wie in Teilabbildung (a) gezeigt.

definiert, dargestellt. Anhand der Beispielwerte wird deutlich, dass für dieses Maß ein Schwellwert aus einem breiteren Bereich gewählt werden kann. Dies gilt bereits, wenn wie im einfachen Beispielszenario nur zwei Attribute zur Beschreibung der Konzepte genutzt. Werden dagegen in einem realistischen Szenario mehr Attribute verwendet, so steigen die Korrespondenzwerte aufgrund der kumulativen Natur des Korrespondenzmaßes für schlecht beschriebene Repräsentanten weiter an. Allerdings ist ein Schwellwert auch in diesem Fall vom vorliegenden Anwendungsfall abhängig, wieder in Form der genutzten Anzahl an Attributen und ihrer Wertebereiche sowie der jeweiligen Diskretisierung dieser Attribute.

Zuordnungsbasiertes Detektionsmaß

Als Grundlage für ein weiteres Bewertungsmaß kann auch die Repräsentant-zu-Konzept Zuordnung genutzt werden. Da diese Zuordnung ebenfalls individuell für Repräsentanten berechnet wird, stellt ein solcher Ansatz auch ein lokales Maß dar. Die Verwendung des Ergebnisses der Repräsentant-zu-Konzept Zuordnung in Form einer diskreten Verteilung über den Konzepten des Hintergrundwissens hat dabei den Vorteil, dass diese Verteilung nicht mehr von der Anzahl an Attributen und deren Wertebereichen abhängt.

Gut beschriebene Repräsentanten zeichnen sich dabei dadurch aus, dass sie relativ eindeutig einem Konzept zugeordnet werden können. Für schlecht beschriebene Repräsentanten ergibt sich dagegen eine inkonklusive Wahrscheinlichkeitsverteilung. Somit unterscheidet sich in beiden Fällen die Konzentration der Wahrscheinlichkeitsmasse der Zuordnungsverteilung, entweder konzentriert auf einem einzelnen Konzept und verteilt über alle Konzepte. Zur Detektion von schlecht beschriebenen Repräsentanten kann daher ein Konzentrationsmaß über der Zuordnungsverteilung genutzt werden wie die Shannon'sche Entropie. Je stärker konzentriert die Wahrscheinlichkeitsmasse einer Zuordnung ist, desto besser ist der Repräsentant dabei beschrieben, und desto kleiner ist die Entropie der Zuordnungsverteilung. Somit spiegelt die Differenz der Entropie der Zuordnungsverteilung zur maximalen Entropie über dem Wertebereich der Verteilung wider, inwiefern ein Repräsentant schlecht beschrieben ist. Als Detektionsmaß kann daher die relative Entropiedifferenz

$$M(p(c|r)) := \frac{\log(|\mathcal{C}|) - H(p(c|r))}{H(p(c|r))} \quad (8.4)$$

der Zuordnungsverteilung $p(c|r)$ zur maximal möglichen Entropie $\log(|\mathcal{C}|)$ genutzt werden.

Abbildung 8.2 stellt die Anwendung dieses Maßes auf unterschiedliche Beispielverteilungen dar. Dabei sind in der ersten Zeile der Abbildung Verteilungen für schlecht beschriebene Repräsentanten dargestellt und in der zweiten Zeile für Repräsentanten, welche eindeutig einem Konzept zugeordnet werden können. Es ist erkennbar, dass die Werte des Detektionsmaßes sich in beiden Fällen deutlich unterscheiden. Zur Detektion von schlecht beschriebenen Repräsentanten kann somit z. B. ein Schwellwert von ≈ 0.5 genutzt werden. Ein zuordnungsbasiertes Detektionsmaß ist zwar unabhängig von den Attributen eines Anwendungsfalls, jedoch nicht von der Größe $|\mathcal{C}|$ der Konzeptmenge. Dieser Effekt wird ebenfalls in Abbildung 8.2 gezeigt: je Spalte variiert dabei die Größe der zugrunde gelegten Konzeptmenge.

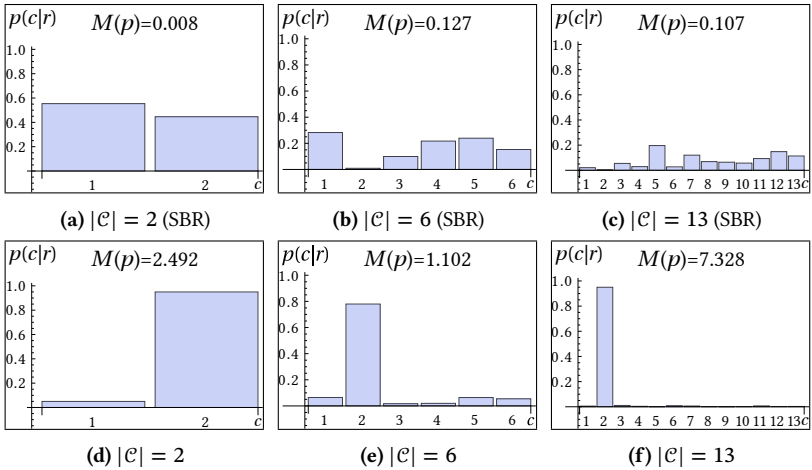


Abbildung 8.2: Beispielhafte Werte für das zuordnungs-basierte Detektionsmaß $M(p(c|r))$ für schlecht beschriebene Repräsentanten (SBR). In der ersten Zeile sind Beispiele für Zuordnungsverteilungen von schlecht beschriebenen Repräsentanten und die entsprechenden Werte des Detektionsmaßes gegeben. Die zweite Zeile stellt Verteilungen für Repräsentanten dar, welche einem der Konzepte des Hintergrundwissens zugeordnet werden können. In beiden Fällen werden unterschiedliche Größen $|C|$ der zugrunde gelegten Konzeptmenge und der Effekt auf das Detektionsmaß betrachtet.

Rückweisungsklassen

Eine einfache Möglichkeit, schlecht beschriebene Repräsentanten bereits bei der Berechnung der Zuordnungsverteilung zu erkennen, stellen Rückweisungsklassen dar. Eine Rückweisungsklasse wird dabei einem Repräsentanten im Ausnahmefall zugeordnet, wenn ihm keines der Konzepte des Hintergrundwissens zugeordnet werden kann. Unterstützt ein Verfahren zur Berechnung der Repräsentant-zu-Konzept Zuordnung als ein mögliches Ergebnis auch eine Rückweisung, so kann dies zur Erkennung von schlecht beschriebenen Repräsentanten genutzt werden. Für die in Abschnitt 6.4.2 beschriebene erweiterte alternative Repräsentant-zu-Konzept Zuordnung könnte eine solche Rückweisung umgesetzt werden für den Fall, dass anhand des Schwellwertvergleichs zum Basiswert für einen Repräsentanten nur insignifikante Ähnlichkeiten zu allen Konzepten festgestellt werden.

Eine solche Rückweisung stellt allerdings eine harte Entscheidung im Sinne eines deterministischen Werts dar. Da in der objektorientierten Umweltmodellierung eine probabilistische Informationsverarbeitung im Vordergrund steht, wurde dieser Ansatz nicht tiefergehend betrachtet.

8.2.3 Untersuchung und Erweiterung des zuordnungsbasierten Detektionsmaßes

Wie in Abbildung 8.2 deutlich wird, kann das zuordnungsbasierte Detektionsmaß $M(\cdot)$ sehr unterschiedliche Werte für den Fall annehmen, dass ein Repräsentant einem Konzept eindeutig zugeordnet werden kann. Dies war die Motivation für eine detaillierte theoretische Betrachtung und Evaluation der Abhängigkeit des Detektionsmaßes von der Größe der Konzeptmenge in [Kuw16], deren Ergebnisse nachfolgend dargestellt werden.

Betrachtung des Falls einer eindeutigen Zuordnung

Dass das Detektionsmaß $M(\cdot)$ von der Größe $|\mathcal{C}|$ der Konzeptmenge abhängt, wird deutlich, wenn man Gleichung (8.4) genauer betrachtet. Dazu wird der Zusammenhang

$$\log(|\mathcal{C}|) = \log(2) + \log(|\mathcal{C}|) - \log(2) = \log(2) + \log\left(\frac{|\mathcal{C}|}{2}\right) \quad (8.5)$$

genutzt und in Gleichung (8.4) eingesetzt, was zu

$$M(p(c|r)) = \frac{\log(|\mathcal{C}|)}{H(p(c|r))} - 1 = \frac{\log(2) + \log(0.5 \cdot |\mathcal{C}|)}{H(p(c|r))} - 1 \quad (8.6)$$

führt. Um den Entropieterm weiter umstellen zu können, wird für eine Konzeptmenge der Größe $|\mathcal{C}| = 2$ die Verteilung $p_e(c|r) = \{p_1, p_2\}$ für eine eindeutige Zuordnung angenommen, wobei p_1 hier den Modalwert der Verteilung beschreibt. Diese Verteilung wird nun auf den Fall einer größeren Konzeptmenge mit $|\mathcal{C}| > 2$ verallgemeinert, indem die Wahrscheinlichkeit von p_2 gleichmäßig auf alle anderen Konzepte verteilt wird. Dies führt zu

der Verteilung

$$p_v(c|r) = \left\{ p_1, \frac{p_2}{|\mathcal{C}| - 1}, \frac{p_2}{|\mathcal{C}| - 1}, \dots, \frac{p_2}{|\mathcal{C}| - 1} \right\}, \quad (8.7)$$

welche genau $|\mathcal{C}| - 1$ Terme enthält, in welchen p_2 auftritt. Die Entropie dieser Verteilung ergibt sich als

$$\begin{aligned} H(p_v(c|r)) &= -p_1 \cdot \log(p_1) - (|\mathcal{C}| - 1) \cdot \frac{p_2}{|\mathcal{C}| - 1} \cdot \log\left(\frac{p_2}{|\mathcal{C}| - 1}\right) \\ &= -p_1 \cdot \log(p_1) - p_2 \cdot \log(p_2) + p_2 \cdot \log(|\mathcal{C}| - 1) \\ &= H(p_e(c|r)) + \log((|\mathcal{C}| - 1)^{p_2}). \end{aligned}$$

Unter Anwendung dieser Annahme kann Gleichung (8.6) dann als

$$M(p_v(c|r)) = \frac{\log(2) + \log(0.5 \cdot |\mathcal{C}|)}{H(p_e(c|r)) + \log((|\mathcal{C}| - 1)^{p_2})} - 1 \quad (8.8)$$

formuliert werden. In dieser Form wird sichtbar, dass für kleine p_2 -Werte nahe 0, wie es für gut beschriebene Repräsentanten üblicherweise der Fall ist, der Zähler dieses Bruchs schneller wächst als der Nenner, wenn die Größe $|\mathcal{C}|$ der Konzeptmenge zunimmt. Dies führt zu erhöhten Werten im zuordnungsbasierten Detektionsmaß $M(\cdot)$. Dieser Umstand wird ebenfalls in Abbildung 8.3 illustriert. Dabei sind die Werte von $M(\cdot)$ nach Gleichung (8.8) für unterschiedliche Werte von p_2 und eine von $|\mathcal{C}| = 2$ bis zu $|\mathcal{C}| = 50$ variierende Größe der Konzeptmenge dargestellt. Die linke Teilabbildung 8.3a stellt die Ergebnisse bis zu einer Größe der Konzeptmenge von $|\mathcal{C}| \leq 10$ dar, die rechte Teilabbildung ab $|\mathcal{C}| \geq 10$ mit geänderter Skalierung. Die Verläufe für unterschiedliche p_2 -Werte nach Gleichung (8.8) sind dabei farblich kodiert: die beige Werte repräsentieren $p_1 = 0.95$ bzw. $p_2 = 0.05$, die violetten Werte $p_1 = 0.65$ bzw. $p_2 = 0.35$. Die grünen Werte (nur in 8.3a) stehen zum Vergleich für einen Grenzfall mit $p_1 = 0.3$ bzw. $p_2 = 0.7$, in welchem nur noch bedingt eine Zuordnung zu einem Konzept vorliegt. Ebenfalls zum Vergleich ist der Verlauf einer Zuordnungsverteilung gezeigt,




Abbildung 8.3: Veranschaulichung der Abhängigkeit des zuordnungsbasierten Detektionsmaßes $M(\cdot)$ von der Größe der Konzeptmenge $|\mathcal{C}|$. Dargestellt sind die Werte des Detektionsmaßes nach Gleichung (8.8) für eine beispielhafte eindeutige Zuordnungsverteilung über unterschiedlich großen Konzeptmengen. Die farblich unterschiedenen Verläufe stellen dabei Werte von $p_1 = 0.95$ bzw. $p_2 = 0.05$ (beige), $p_1 = 0.65$ bzw. $p_2 = 0.35$ (violett) und $p_1 = 0.3$ bzw. $p_2 = 0.7$ (grün) in Gleichung (8.8) dar. Zum Vergleich ist die Zuordnungsverteilung eines schlecht beschriebenen Repräsentanten in blau dargestellt. Die linke Teilabbildung (a) zeigt die Werte bis zu einer Größe $|\mathcal{C}| \leq 10$ der Konzeptmenge, die rechte Teilabbildung (b) für $|\mathcal{C}| \geq 10$.

welche den Fall eines schlecht beschriebenen Repräsentanten darstellt. Aus der Abbildung wird deutlich, dass die Trennung der beiden Fälle nur für kleine Größen des Hintergrundwissens problematischer ist. Je mehr Konzepte im Hintergrundwissen enthalten sind, desto mehr unterscheiden sich die Fälle unter Anwendung des zuordnungsbasierten Detektionsmaßes. So kann z. B. ein Schwellwert von 0.25 zur Detektion von schlecht beschriebenen Repräsentanten genutzt werden.

Betrachtung des Falls von schlecht beschriebenen Repräsentanten

Um die Abhängigkeit des Detektionsmaßes $M(\cdot)$ von der Größe der Konzeptmenge auch im Fall der Zuordnungsverteilung eines schlecht beschriebenen Repräsentanten untersuchen zu können, wird ein einfaches Modell für diese Verteilung genutzt. Dabei wird zunächst eine Zuordnungsverteilung von $p_s(c|r) := \{p_3, p_4, p_5\}$ angenommen für eine Konzeptmenge der Größe $|\mathcal{C}| = 3$. Die einzelnen Werte spielen dabei nur eine untergeordnete Rolle, werden aber als ähnlich groß angenommen. Um die Auswirkung

unterschiedlicher Größen der Konzeptmenge modellieren zu können, wird diese Verteilung erweitert, indem die drei Werte k -fach kopiert werden und die Verteilung entsprechend normiert wird. Dies ergibt die Verteilung

$$p_{s,k}(c|r) := \left\{ \frac{p_3}{k}, \frac{p_4}{k}, \frac{p_5}{k}, \frac{p_3}{k}, \frac{p_4}{k}, \frac{p_5}{k}, \dots, \frac{p_3}{k}, \frac{p_4}{k}, \frac{p_5}{k} \right\}. \quad (8.9)$$

Diese Verteilung modelliert aufgrund ihrer kopierten Struktur eine Art verauschte Gleichverteilung für hinreichend große k . Die Entropie dieser Verteilung ergibt sich als

$$H(p_{s,k}(c|r)) = -p_3 \cdot \log\left(\frac{p_3}{k}\right) - p_4 \cdot \log\left(\frac{p_4}{k}\right) - p_5 \cdot \log\left(\frac{p_5}{k}\right) \quad (8.10)$$

$$= H(p_s(c|r)) + (p_3 + p_4 + p_5) \cdot \log(k) \quad (8.11)$$

$$= H(p_s(c|r)) + \log(|\mathcal{C}_{s,k}|) - \log(|\mathcal{C}_s|) \quad (8.12)$$

unter Verwendung der Beziehung $|\mathcal{C}_{s,k}| = k \cdot |\mathcal{C}_s|$ zwischen der Größe der kopierten und der ursprünglichen Konzeptmenge. Vergleicht man nun den Wert von $M(\cdot)$ für die ursprüngliche Verteilung, $\log(|\mathcal{C}_s|) - H(p_s(c|r))$, gegen den Wert für die kopierte Verteilung,

$$\log(|\mathcal{C}_{s,k}|) - H(p_{s,k}(c|r)) \quad (8.13)$$

$$= \log(|\mathcal{C}_{s,k}|) - H(p_s(c|r)) - \log(|\mathcal{C}_{s,k}|) + \log(|\mathcal{C}_s|) \quad (8.14)$$

$$= \log(|\mathcal{C}_s|) - H(p_s(c|r)) , \quad (8.15)$$

so wird deutlich, dass der Wert von $M(\cdot)$ nicht von der Größe der Konzeptmenge abhängt – im Fall der Zuordnungsverteilung eines schlecht beschriebenen Repräsentanten und unter Annahme der kopierten Struktur einer solchen Verteilung.

Diese Betrachtungen bestätigen die grundsätzliche Anwendbarkeit des zuordnungsbasierten Detektionsmaßes $M(\cdot)$ für schlecht beschriebene Repräsentanten. Darüber hinaus ist für eine solche Detektion allerdings auch ein Maß vorteilhaft, welches eine geringere Abhängigkeit von der Größe der Konzeptmenge besitzt und den Abstand der Werte für gut gegenüber

schlecht beschriebenen Repräsentanten vergrößert. Ausgehend von den vorhergehenden Betrachtungen kann zu diesem Zweck ein Ansatz genutzt werden, welcher sich nicht wie $M(\cdot)$ auf die Entropie der betrachteten Verteilung im Nenner bezieht, sondern auf die Größe der Konzeptmenge bzw. die aus ihr resultierende maximale Entropie $\log(|\mathcal{C}|)$. Mit diesem Ansatz kann ein alternatives zuordnungsbasiertes Detektionsmaß $M_2(\cdot)$ definiert werden, welches auf das Intervall $[0,1]$ beschränkt ist und sich als

$$M_2(p(c|r)) := 1 - \frac{H(p(c|r))}{\log(|\mathcal{C}|)} \quad (8.16)$$

ergibt. Die Eigenschaften dieses alternativen Maßes sind in Abbildung 8.4 illustriert. Es ist erkennbar, dass das Maß weniger von der Größe der Konzeptmenge $|\mathcal{C}|$ abhängig ist und allgemein eine bessere Unterscheidung der Fälle von gut gegenüber schlecht beschriebenen Repräsentanten erlaubt.




Abbildung 8.4: Veranschaulichung der Abhängigkeit des alternativen zuordnungsbasierten Detektionsmaßes $M_2(\cdot)$ von der Größe der Konzeptmenge $|\mathcal{C}|$. Dargestellt sind die Werte des Detektionsmaßes nach Gleichung (8.16) für eine beispielhafte eindeutige Zuordnungsverteilung über unterschiedlich große Konzeptmengen. Die farblich unterschiedenen Verläufe stellen dabei Werte von $p_1 = 0.9$ bzw. $p_2 = 0.1$ (beige) und $p_1 = 0.65$ bzw. $p_2 = 0.35$ (violett) dar. Zum Vergleich ist die Zuordnungsverteilung eines schlecht beschriebenen Repräsentanten in blau dargestellt. Die linke Teilabbildung (a) zeigt Werte für $|\mathcal{C}| \leq 10$, die rechte Teilabbildung (b) für $|\mathcal{C}| \geq 10$.

8.2.4 Evaluation

Zur Demonstration der beschriebenen globalen und lokalen Detektionsmaße wurde das bereits bekannte einfache Demonstrationsszenario verwendet, welches in Abschnitt 6.3.2 definiert wurde. Abbildung 8.5 stellt die Ergebnisse für unterschiedliche Detektionsmaße über den Verlauf des Szenarios von sieben Zeitschritten dar.




Abbildung 8.5: Demonstration von verschiedenen Detektionsmaßen für schlecht beschriebene Repräsentanten im einfachen Demonstrationsszenario (vgl. Abschnitt 7.6.3). Dargestellt sind die Werte des lokalen Detektionsmaßes $M(\cdot)$ und der beiden globalen Maße $g_1^a(\cdot)$ und $g^r(\cdot)$ über die sieben Zeitschritte des Szenarios. In den Zeitschritten 5–6 (roter Kasten) liegen dabei schlecht beschriebene Repräsentanten vor, welche von allen drei Maßen detektiert werden. Für die beiden globalen Maße, welche die absolute oder relative Änderung der Modellkorrespondenz durch den im Zeitschritt beobachteten Repräsentanten darstellen, werden schlecht beschriebene Repräsentanten durch ein sprunghaftes Ansteigen dargestellt. Für die relative Entropiedifferenz $M(\cdot)$ ist dies für Werte nahe 0 der Fall.

Der zeitliche Ablauf ist identisch zu dem in Abschnitt 7.6.3 beschriebenen Ablauf zur Evaluation der quantitativen Modellbewertung. Als Referenz sind in Abbildung 8.5 daher auch die Gütemaße der Modellbewertung nochmals in grau dargestellt. Als Demonstrationsergebnisse sind die Werte der relativen Entropiedifferenz $M(\cdot)$ nach Gleichung (8.4) als lokales Detektionsmaß

sowie von zwei globalen Schrittmaßen, der absoluten Änderung der Modellkorrespondenz $g_1^a(\cdot)$ nach Gleichung (8.2) und der relativen Änderung $g^r(\cdot)$ nach Gleichung (8.3), dargestellt. Schlecht beschriebene Repräsentanten treten dabei nur in den Schritten $t = 5$ und $t = 6$ auf, welche in der Abbildung durch einen roten Kasten hervorgehoben sind. Für alle drei dargestellten Detektionsmaße sind in diesen Zeitschritten deutlich veränderte Werte gegenüber den restlichen Zeitschritten festzustellen. Jeder der Zeitschritte von $t = 2$ bis $t = 6$ repräsentiert dabei die Aufnahme eines neuen Repräsentanten ins Weltmodell, wie durch die entsprechenden Namen der Repräsentanten in der Abbildung angedeutet. Die globalen Schrittmaße zeigen für die Zeitschritte $t = 5$ und $t = 6$ dabei deutlich höhere Werte als z. B. in den Schritten zuvor, und die relative Entropiedifferenz zeigt Werte nahe 0 für die schlecht beschriebenen Repräsentanten. Beides entspricht dem erwarteten Verhalten und demonstriert die grundsätzliche Anwendbarkeit der Maße.

8.3 Adaptive Verwaltung von Hintergrundwissen

Die Anpassung eines Hintergrundwissensmodells durch die adaptive Umweltmodellierung soll nach bestimmten Prinzipien erfolgen. Dazu zählt die Bedarfsgerechtigkeit einer Anpassung, die Relevanz der eingebrachten Änderungen sowie ein Ausgleich zwischen Komplexität und Beschreibungsfähigkeit des verwendeten Modells. Dieser Ausgleich sowie die Bedarfsgerechtigkeit einer Anpassung kann durch die Gütemaße der quantitativen Modellbewertung adressiert werden. Durch Modellanpassungen werden neue oder aktualisierte Konzepte für die Typen von nur schlecht durch das Hintergrundwissensmodell beschriebenen Entitäten dem Hintergrundwissen hinzugefügt. Die Relevanz einer solchen Anpassung spiegeln sich somit in der Häufigkeit wider, mit welcher schlecht beschriebene Entitäten eines bestimmten Typs während des Betriebs eines Umweltmodells in der Umgebung beobachtet werden. Das Auftreten solcher Entitäten kann dabei durch die zuvor beschriebenen Detektionsmaße festgestellt werden. Um über die

Häufigkeit des Auftretens auf die Relevanz von Entitäten bzw. Typen von Entitäten schließen zu können, muss zusätzlich über dieses Auftreten Buch geführt werden. Dies ist eine der Aufgaben der adaptiven Wissensverwaltung. Zu diesem Zweck wird dort eine Liste \mathcal{S}_R der bisher detektierten schlecht beschriebenen Repräsentanten zusammen mit dem Zeitpunkt ihres Auftretens geführt. Wird zu einem Zeitpunkt ein oder mehrere aktualisierte Repräsentanten durch ein Detektionsmaß als schlecht beschrieben identifiziert, so werden diese Repräsentanten in die Liste aufgenommen.

Weiterhin wird die Gesamtgüte des Modells durch die Maße der quantitativen Modellbewertung bestimmt. Ist diese Güte nicht mehr ausreichend, so wird ein Anpassungsvorgang angestoßen, welchem die geführte Liste der Repräsentanten als Ausgangsbasis dient. Bei diesem Anpassungsvorgang wird auch beachtet, inwiefern die Aufnahme neuer oder aktualisierter Konzepte in das Hintergrundwissen zu einer Verbesserung der Modellgüte führt. Somit wird auch hier die Relevanz von Modellanpassungen beachtet und bewertet. Für die adaptive Modellverwaltung wird dabei in jedem Zeitschritt eine Regelschleife ausgeführt, welche nachfolgend vorgestellt wird. Anschließend werden die einzelnen Teilaufgaben innerhalb dieser Regelschleife genauer beschrieben. Die Darstellungen basierend auf [Kuw14].

8.3.1 Regelschleife der adaptiven Modellverwaltung

Algorithmus 1 beschreibt das grundlegende Vorgehen der adaptiven Modellverwaltung als eine Regelschleife. Durch diesen Algorithmus erfolgt somit die Umsetzung der adaptiven Umweltmodellierung und ihrer Prinzipien unter Verwendung der zuvor beschriebenen Methoden und Bewertungsmaße. Der Algorithmus wird prinzipiell in jedem Zeitschritt ausgeführt. Aus Effizienzgründen kann allerdings auch eine Ausführung mit verringerter Frequenz im Umweltmodell vorgesehen werden. Die äußere Schleife des Algorithmus ist daher auch als symbolisch zu sehen, da der Algorithmus pro Zeitschritt mit den anderen Verarbeitungsschritten der Informationsverwaltung im Umweltmodell koordiniert werden muss. In der Beschreibung des

Algorithmen werden schlecht beschriebene Repräsentanten als SBR abgekürzt. Die einzelnen Teilschritte des Algorithmus und somit auch die Umsetzung der adaptiven Umweltmodellierung werden nachfolgend detailliert erläutert.

Algorithmus 1 Adaptive Modellverwaltung

```
1: # Eingabe: Weltmodell  $\mathcal{R}$ , Hintergrundwissen  $\mathcal{C}$ 
2:  $\mathcal{S}_{\mathcal{R}} := \{\}$ ;
3: while System läuft im Zeitschritt  $t_n$  do
4:    $\mathcal{S}_{\mathcal{R}}^x := \{\}$ ;
5:    $\mathcal{S}_{\mathcal{R}} =$  Detektiere SBR ( $\mathcal{R}, \mathcal{C}, \mathcal{S}_{\mathcal{R}}$ );
6:   while Prüfe Modellgüte ( $\mathcal{R}, \mathcal{C}$ ) do # Modellanpassung anstoßen
7:      $s^* =$  Bewerte SBR und wähle ( $\mathcal{S}_{\mathcal{R}} \setminus \mathcal{S}_{\mathcal{R}}^x$ );
8:      $\mathcal{S}_{\mathcal{R}}^* =$  Finde Lernbeispiele ( $s^*, \mathcal{S}_{\mathcal{R}}$ );
9:      $c^* =$  Berechne Modellanpassung ( $\mathcal{C}, \mathcal{S}_{\mathcal{R}}^*$ );
10:    # Erneute Prüfung Modellqualität: Annehmen der Anpassung?
11:    if Prüfe Modellgüte über Betriebszeit ( $\mathcal{R}_{0:n}, \mathcal{C}_{0:n}, c^*$ ) then
12:       $\mathcal{C} =$  Integriere Konzept ( $c^*, \mathcal{C}$ ); # Aktualisiere Modell
13:       $\mathcal{S}_{\mathcal{R}} =$  Aktualisiere SBR-Liste ( $\mathcal{S}_{\mathcal{R}}, c^*$ );
14:    else
15:       $\mathcal{S}_{\mathcal{R}}^x = \mathcal{S}_{\mathcal{R}}^x \cup \mathcal{S}_{\mathcal{R}}^*$ ; # Markiere als abgearbeitet
16:    end if
17:    # Führe weitere Anpassungen durch falls notwendig
18:  end while
19: end while
```

Detektiere SBR In diesem ersten Schritt werden unter Verwendung eines der vorgeschlagenen Detektionsmaße die im Zeitschritt t_n aktualisierten Repräsentanten darauf geprüft, ob sie durch das aktuelle Hintergrundwissensmodell nur schlecht beschrieben werden können. Ist dies der Fall, werden die

entsprechenden Repräsentanten zur Liste der schlecht beschriebenen Repräsentanten $\mathcal{S}_{\mathcal{R}}$ für den aktuellen Zeitpunkt hinzugefügt.

Prüfe Modellgüte Hier wird die Veränderung der Güte des Modells im aktuellen Zeitpunkt t_n gegenüber der Güte Q_{t_l} des letzten Zeitpunkts t_l einer Modellanpassung bewertet. Unter Verwendung der Maße der quantitativen Modellbewertung kann dies z. B. als

$$Q(\mathcal{R}_{t_n}, \mathcal{C}) - Q_{t_l} \geq \Phi_Q, \quad 0 \leq l < n, \quad (8.17)$$

erfolgen, wobei hier explizit der Zustand des Weltmodells \mathcal{R}_{t_n} zum Zeitpunkt t_n referenziert wird. Über einen Schwellwert Φ_Q wird dabei bewertet, wann die Güte eines Modells zu sehr abgefallen ist, im Sinne eines Anstiegs des Bewertungsmaßes $Q(\cdot)$, und ob eine Modellanpassung notwendig ist.

Bewerte SBR und wähle Im Fall einer durchzuführenden Modellanpassung wird zunächst für jeden schlecht beschriebenen Repräsentanten in der Liste $\mathcal{S}_{\mathcal{R}}$ dessen Relevanz bzw. dessen geschätzte Nützlichkeit für ein angepasstes Modell bewertet. Als Ergebnis wird dann der relevanteste bzw. nützlichste Repräsentant s^* als Kandidat für eine Modellanpassung ausgewählt. Dabei werden in der Liste $\mathcal{S}_{\mathcal{R}}$ nur Repräsentanten beachtet, welche im aktuellen Zeitschritt noch nicht betrachtet wurden. Bereits betrachtete Repräsentanten werden in der Liste $\mathcal{S}_{\mathcal{R}}^x$ gespeichert. Die Details zum Vorgehen für die Auswahl von s^* werden in Abschnitt 8.3.2 vorgestellt.

Finde Lernbeispiele Das Ziel in diesem Schritt ist es, für den ausgewählten Kandidaten-Repräsentanten s^* alle diejenigen schlecht beschriebenen Repräsentanten auszuwählen, welche zum gleichen Typ von Entität wie s^* gehören. Als Ergebnis dieses Schritts wird dann eine Menge $\mathcal{S}_{\mathcal{R}}^*$ von Lernbeispielen zurückgegeben. Dieser Schritt wird ebenfalls in Abschnitt 8.3.2 genauer beschrieben.

Berechne Modellanpassungen Auf Basis der ausgewählten Lernbeispiele $\mathcal{S}_{\mathcal{R}}^*$ und des bisherigen Hintergrundwissens kann in diesem Schritt ein aktualisiertes Konzept c^* gelernt werden. Dabei muss auch entschieden werden, ob ein existierendes Konzept aktualisiert werden soll oder ob ein neues

Konzept gelernt werden muss. Für ein neues Konzept muss weiterhin auch die Stelle identifiziert werden, an welcher dieses anschließend in das Hintergrundwissensmodell eingeordnet werden kann. Auf das Thema des Konzeptlernens an sich geht Abschnitt 8.4 genauer ein. Vorgelagerte Aspekte werden in Abschnitt 8.3.3 beschrieben.

Prüfe Modellgüte über bisherige Betriebszeit Bevor ein aktualisiertes Konzept c^* in das Hintergrundwissensmodell integriert wird, muss zunächst die Relevanz dieser Anpassung für das objektorientierte Umweltmodell bewertet werden. Dabei wird nicht nur der aktuelle Zeitschritt betrachtet, sondern die gesamte gespeicherte Historie des Umweltmodells. Die Frage, die durch diese Betrachtung beantwortet werden soll, ist, wie nützlich das aktualisierte Konzept über die bisherige Betriebszeit des Umweltmodells zur Beschreibung der beobachteten Repräsentanten gewesen wäre. Genauer gesagt wird dabei die Verbesserung der Modellgüte betrachtet, welche durch Aufnahme des Konzepts in das Hintergrundwissensmodell in Bezug auf den bisherigen Betrieb hätte erreicht werden können. Diese Verbesserung wird als die Relevanz des aktualisierten Konzepts für das Umweltmodell interpretiert. Zur Bewertung dieser Verbesserung wird die akkumulierte historische Modellgüte unter Verwendung des aktuellen Hintergrundwissens mit der akkumulierten hypothetischen Modellgüte unter der zusätzlichen Verwendung des aktualisierten Konzepts verglichen als

$$\sum_{i=0}^n \underbrace{Q(\mathcal{R}_{t_i}, c \cup \{c^*\})}_{\text{hypothetische Güte}} \stackrel{?}{\leq} \sum_{i=0}^n \underbrace{Q(\mathcal{R}_{t_i}, c)}_{\text{bisherige Güte}}. \quad (8.18)$$

Kann dabei eine Verbesserung erreicht werden, ist also der Wert der Gütebewertung für die hypothetische Güte kleiner als der Wert des aktuellen Modells, so wird das aktualisierte Konzept im nächsten Schritt in das Hintergrundwissensmodell aufgenommen.

Integriere Konzept In diesem Schritt wird das aktualisierte Konzept c^* in das Hintergrundwissensmodell an der identifizierten Stelle aufgenommen und somit die tatsächliche Modellanpassung durchgeführt.

Aktualisierung der Verwaltungslisten Nach einer erfolgreichen Modellanpassung muss die Liste der schlecht beschriebenen Repräsentanten $S_{\mathcal{R}}$ aktualisiert werden. Dabei müssen all diejenigen Repräsentanten entfernt werden, welche nun durch das angepasste Hintergrundwissen gut beschrieben werden können. Falls das aktualisierte Konzept nicht ins Hintergrundwissen aufgenommen wird, so muss zumindest die Liste $S_{\mathcal{R}}^x$ der in diesem Schritt betrachteten schlecht beschriebenen Repräsentanten aktualisiert werden. Hierbei werden alle als Lernbeispiele ausgewählten Repräsentanten als abgearbeitet markiert, da all diese denselben Typ von Entität repräsentieren und bei einer erneuten Ausführung der inneren Schleife nicht nochmals betrachtet werden sollen.

Weitere Iterationen und Abbruch Nach dem ersten Durchlauf durch die innere Schleife des Modellverwaltungsalgorithmus wird erneut die Modellgüte geprüft. Fand eine Anpassung statt und ist die Güte nun gut genug (in Vergleich zu Q_{t_i} , analog zum Schritt „Prüfe Modellgüte“), so wird die Schleife abgebrochen. Gleichzeitig werden der aktuelle Zeitpunkt t_n und Gütewert Q_{t_n} als neue Basiswerte für zukünftige Vergleiche gespeichert.

Hat sich die Modellgüte dagegen noch nicht ausreichend verbessert, entweder, weil die Anpassung nicht ausreichend war oder gar keine Anpassung vorgenommen wurde, so wird die innere Schleife erneut durchlaufen, auf Basis der in diesem Zeitschritt noch nicht betrachteten schlecht beschriebenen Repräsentanten $S_{\mathcal{R}} \setminus S_{\mathcal{R}}^x$. Wurden in einem Zeitschritt bereits alle schlecht beschriebenen Repräsentanten betrachtet, so wird die innere Schleife ebenfalls abgebrochen (dies ist im Algorithmus nicht explizit dargestellt).

8.3.2 Auswahl relevanter Lernkandidaten

Zuvor wurde das grundlegende Vorgehen der adaptiven Modellverwaltung in Form der in Algorithmus 1 beschriebenen Regelschleife dargestellt. In diesem und in den nachfolgenden Abschnitten werden nun einige der Teilschritte dieser Regelschleife vertiefend dargestellt.

In der adaptiven Modellverwaltung muss, sobald der Bedarf für eine Modellanpassung festgestellt wurde, eine geeignete Menge von Lernbeispielen als Datengrundlage einer solchen Anpassung ausgewählt werden. Dazu muss eine Gruppierung aller schlecht beschriebenen Repräsentanten in der Liste $\mathcal{S}_{\mathcal{R}}$ stattfinden. Diese Gruppierung beschreibt dabei ein Problem der unüberwachten Clusteranalyse. In der adaptiven Umweltmodellierung sollen durch eine solche Gruppierung zwei Probleme gelöst werden. Zunächst soll die Relevanz der einzelnen, in der Liste enthaltenen Repräsentanten bewertet werden, da Relevanz eines der Leitprinzipien der adaptiven Umweltmodellierung ist. Weiterhin muss beachtet werden, dass durch die Konzepte des Hintergrundwissens nicht einzelne Entitäten, sondern Typen von Entitäten modelliert werden. Somit müssen als Menge von Lernbeispielen für ein neues Konzept all diejenigen Repräsentanten ausgewählt werden, welche Instanzen desselben Typs darstellen. Dieses zweite Problem muss unüberwacht gelöst werden, da der Typ der Entitäten nicht bekannt ist.

Relevanzbewertung für Repräsentanten

Die adaptive Modellverwaltung geht zur Lösung dieser beiden Probleme in zwei Schritten vor. In Zeile 7 von Algorithmus 1 wird zunächst eine Relevanzbewertung aller noch nicht betrachteten Repräsentanten in $\mathcal{S}_{\mathcal{R}}$ durchgeführt. Die Relevanz eines Repräsentanten wird in der adaptiven Umweltmodellierung über die Häufigkeit seines Auftretens identifiziert. Allerdings soll auch hier nicht die Relevanz eines einzelnen Repräsentanten bewertet werden, sondern die des zugehörigen Entitätstyps. Somit muss zur Relevanzbewertung eines Repräsentanten gezählt werden, wie oft eine Instanz des durch ihn (bzw. seine Entität) dargestellten Typs in der Liste $\mathcal{S}_{\mathcal{R}}$ vorkommt. Zur Bewertung, ob ein Repräsentant eine Instanz desjenigen Typs darstellt, welche durch einen anderen Repräsentanten beschrieben wird, wird an dieser Stelle als Maß eine Beschreibungslänge genutzt. Diese Beschreibungslänge repräsentiert, wie viel Beschreibung für den Repräsentanten benötigt wird, wenn als Modell ein anderer Repräsentant genutzt wird. Ist diese Länge hinreichend klein, so kann dieser Repräsentant als eine Instanz des Typs des

anderen Repräsentanten betrachtet werden. Zu diesem Zweck kann als Bewertungsmaß die Konzeptkorrespondenz $L(\cdot | \cdot)$ nach Gleichung (7.8) eingesetzt werden. Da Repräsentanten und Konzepte jeweils über Attributmengen beschrieben werden und somit syntaktisch gleichartig darstellbar sind, können formal auch Repräsentanten in der Rolle eines potentiellen Konzepts in das Bewertungsmaß $L(\cdot | \cdot)$ eingesetzt werden. Daher kann nun die Relevanz eines schlecht beschriebenen Repräsentanten s bzw. die Relevanz des durch ihn dargestellten Entitätstyps als die Größe

$$r(s) := \left| \{ \bar{s} \in \mathcal{S}_{\mathcal{R}} \mid L(\bar{s} | s) < \Phi_r^L \} \right| \quad (8.19)$$

der Menge der zum Repräsentanten im Sinne einer Beschreibungslänge hinreichend ähnlichen weiteren Repräsentanten aus $\mathcal{S}_{\mathcal{R}}$ berechnet werden. Der Schwellwert Φ_r^L beschreibt hier die maximal erlaubte Beschreibungslänge. Als Stellvertreter für den als am relevantesten bewerteten Typ von Entität wird dann derjenige Repräsentant aus $\mathcal{S}_{\mathcal{R}}$ ausgewählt, welcher Gleichung (8.19) maximiert, also die größte Anzahl an geschätzten Instanzen besitzt. Dieser Repräsentant dient dann als Kandidat s^* für eine Modellanpassung.

Geschätzte Nützlichkeit von Repräsentanten

Als Alternative zu einer über die Typ-Auftrittshäufigkeit bewerteten Relevanz kann auch die geschätzte Nützlichkeit eines Repräsentanten für eine Modellanpassung als Auswahlkriterium genutzt werden. Die geschätzte Nützlichkeit bewertet dabei, wie viel weniger Beschreibung benötigt wird, wenn als zusätzliches Konzept der betrachtete Repräsentant ins Hintergrundwissensmodell aufgenommen wird. Auch hier wird für eine Umsetzung dieses Ansatzes wieder die syntaktische Ähnlichkeit von Repräsentanten und Konzepten ausgenutzt und der betrachtete Repräsentant s hypothetisch der Konzeptmenge \mathcal{C} hinzugefügt. Für diese erweiterte Konzeptmenge wird dann berechnet, um wie viel die Beschreibung des Weltmodells nun kürzer ist gegenüber der Beschreibung unter der ursprünglichen Konzeptmenge ohne diesen Repräsentanten. Eine solche Nützlichkeit

kann unter Verwendung der Modellkorrespondenz als die Differenz

$$\Delta L(s) := L(\mathcal{R}_{t_n} \mid \mathcal{C}) - L(\mathcal{R}_{t_n} \mid \mathcal{C} \cup \{s\}) \quad (8.20)$$

beschrieben werden. Für diesen Ansatz wird dann der Repräsentant mit der höchsten Nützlichkeit als Kandidat s^* für Modellanpassungen ausgewählt.

Finden von Lernbeispielen

Um den zweiten Teil des Gruppierungsproblems zu lösen, müssen nun als Lernbeispiele (Zeile 8 in Algorithmus 1) alle Repräsentanten gefunden werden, welche zum ausgewählten Kandidat s^* hinreichend ähnlich sind. Zur Bewertung der Ähnlichkeit zwischen Repräsentanten und Konzepten wird in der objektorientierten Umweltmodellierung die Repräsentant-zu-Konzept Zuordnung genutzt. Auch in diese kann anstelle eines Konzepts ein Repräsentant eingesetzt werden, aufgrund der syntaktisch gleichartigen Darstellung von Repräsentanten und Konzepten. Somit kann die Menge der Lernbeispiele für eine Modellanpassung auf Basis des Kandidaten s^* als

$$\mathcal{S}_{\mathcal{R}}^* := \{s \in \mathcal{S}_{\mathcal{R}} \mid p(s^*|s) > \Phi_S^p\} \quad (8.21)$$

berechnet werden, wobei Φ_S^p hier einen Schwellwert für die Ähnlichkeitsbewertung darstellt. Dieser Schwellwert kann dabei analog zum Vorgehen der erweiterten Repräsentant-zu-Konzept Zuordnung (vgl. Abschnitt 6.4) als ein Vielfaches eines Basiswerts festgelegt werden.

8.3.3 Durchführung von Modellanpassungen

Für eine Modellanpassung muss aufgrund der Lernbeispiele ein aktualisiertes Konzept gelernt werden. Bevor ein solches Konzept gelernt werden kann, muss zunächst entschieden werden, ob ein existierendes Konzept durch den Lernvorgang angepasst oder ein gänzlich neues Konzept gelernt werden soll. Als ein Ansatzpunkt für eine solche Entscheidung können die definierten Detektionsmaße für schlecht beschriebene Repräsentanten genutzt werden,

z. B. die zuordnungsbasierten lokalen Detektionsmaße $M(\cdot)$ bzw. $M_2(\cdot)$. Um zu entscheiden, ob ein Konzept im Hintergrundwissen existiert, das ähnlich genug zu den Lernbeispielen ist, kann z. B. die mittlere relative Entropiedifferenz für relevante Konzepte berechnet werden. Liegt der beste (niedrigste) dieser Werte innerhalb eines festgelegten Intervalls, so kann das entsprechende Konzept für eine Erweiterung in Betracht gezogen werden. Dieser Aspekt wurde in dieser Arbeit allerdings nicht tiefergehend betrachtet. Eine detaillierte Untersuchung der Problemstellung verbleibt daher eine zukünftige Arbeit.

Nachdem eine Modellanpassung durchgeführt wurde, muss das aktualisierte Konzept in das Hintergrundwissensmodell integriert werden. Wurde dabei ein existierendes Konzept aktualisiert, so ist dessen Einordnung ins Hintergrundwissensmodell bereits gegeben. Wurde dahingegen ein gänzlich neues Konzept gelernt, so kann dieses zwar in die Konzeptmenge \mathcal{C} (als ein flaches Wissensmodell) aufgenommen werden, muss aber schließlich noch in der Taxonomie des hierarchischen Wissensmodells verortet werden. Auch für diese Aufgabe können die definierten Ähnlichkeitsmaße genutzt werden, um im bisherigen Hintergrundwissensmodell Hinweise auf mögliche Einhängpunkte für das neu gelernte Konzept zu finden. Für eine tatsächliche Verortung im Hintergrundwissensmodell müssen allerdings auch weitere Aspekte beachtet werden, die sich aus den Entwurfsprinzipien des Hintergrundwissensmodells ergeben, wie z. B. Grundsätze der formalen Ontologie. Daher ist in dieser Arbeit keine automatisierte Verortung neu gelernter Konzepte in einem hierarchischen Wissensmodell vorgesehen, sondern eine manuelle Verortung unter menschlichem Eingreifen.

Für ein neu gelerntes Konzept müssen auch weitere Aspekte beachtet werden. Dazu zählt beispielsweise, dass das Konzept durch einen sprechenden Namen beschrieben werden muss. Darüber hinaus müssen die nicht beobachtbaren semantischen Aspekte des Konzepts ergänzt werden, in Form von semantischen Attributen und Relationen. Ein erster Ansatz, wie dies unter Verwendung von existierenden, externen Wissensbasen umgesetzt werden kann, wird in [Kuw15] beschrieben. Dabei werden verschiedene Aufgaben

betrachtet. Als eine erste Aufgabe wird das erwähnte Ableiten eines sprechenden Namens für ein Konzept betrachtet. Auf dem Ergebnis dieser Aufgabe aufbauend wird als zweite Aufgabe das Extrahieren von zusätzlichen Attributen aus existierenden Wissensmodellen unter Verwendung des Konzeptnamens betrachtet.

Als Lösungsansatz für die erste Aufgabe wurden in [Kuw15] unterschiedliche, über das World Wide Web ansprechbare Dienste betrachtet, welche für einen gegebenen Bildausschnitt entsprechende Klassennamen als Ergebnis liefern. Die für diesen Lösungsansatz benötigten Bildausschnitte müssten in der objektorientierten Umweltmodellierung dabei direkt von der Sensorik eines kognitiven Systems bezogen werden. Durch eine erste Umsetzung dieses Ansatzes und unter Verwendung von beispielhaften Bildausschnitten konnte evaluiert werden, dass ein solcher Lösungsansatz zumindest für einige der betrachteten Objekte die gewünschten Klassennamen liefern kann¹. Zugleich hat sich bei diesem Ansatz als problematisch erwiesen, dass einerseits die mitgelieferten Konfidenzwerte für einen Klassennamen sich über unterschiedliche Dienste teilweise deutlich unterscheiden, und andererseits ein Ansatz oftmals unterschiedliche Klassennamen mit gleicher Konfidenz zurückliefert. Diese unterschiedlichen Klassennamen beschreiben dabei häufig Klassen, die in einer semantischen Generalisierungsbeziehung („is-a“-Relation) stehen. Durch einen ebenfalls in [Kuw15] betrachteten einfachen Fusionsansatz über die Ergebnisse unterschiedlicher Dienste konnten für beide Probleme erste Verbesserungen erzielt werden.

Als Lösungsansatz für die zweite Aufgabe wurde die Extraktion von Attributwerten aus der Cyc² Top-Level Ontologie und Datenbank (vgl. Abschnitt 2.3.2) betrachtet. Ein erstes Problem war hierbei, auf Basis eines gegebenen Namens das richtige Konzept in der Datenbank auszuwählen, d. h. also eine semantische Disambiguierung des Namens durchzuführen. Als ein erster

¹ Da diese Auswertung schon einige Zeit zurückliegt, sollte sich im Verlauf der Zeit analog zur Entwicklung des allgemeinen Standes der Technik im Bereich der Objektklassifikation auch für solche web-basierten Dienste die Erkennungsleistung nochmals deutlich verbessert haben.

² Dabei wurde die „ResearchCyc“ Variante genutzt.

Ansatz wurde in [Kuw15] eine einfache Heuristik umgesetzt, die dasjenige Konzept auswählt, für welches in seinen untergeordneten Konzepten der gesuchte Name am häufigsten auftritt. Diese Heuristik war für eine einfache Demonstration ausreichend, wurde darüber hinaus aber nicht tiefergehend evaluiert. Unter Anwendung dieser Heuristik war es möglich, zumindest für einige der betrachteten Konzepte einige wenige relevante Attributwerte zu extrahieren. Allerdings stellten die extrahierten Attributwerte für die betrachteten Konzepte häufig eher unspezifische Intervalle von Werten dar.

Das Problem der Ergänzung von neu gelernten Konzepten durch semantische Attribute bedarf daher noch einer vertieften Betrachtung. Zu diesem Zweck können auch Verfahren des Ontologie-Lernens hilfreich sein, welche in dieser Arbeit allerdings nicht weiter betrachtet wurden.

8.4 Lernen probabilistischer Konzepte

In der adaptiven Umweltmodellierung besteht die Aufgabe des Konzeptlernens daraus, aus einer gegebenen Menge von Lernbeispielen eine neue Konzeptdefinition abzuleiten. Die Ausgangssituation ist dabei ähnlich wie die des klassischen Konzeptlernens oder der konzeptuellen Clusteranalyse (vgl. Abschnitt 2.4.1). Dabei soll jeweils auf Grundlage einer relativ geringen Menge von Beispielen durch induktive Inferenz die Beschreibung eines generalisierten Konzepts abgeleitet werden. Induktive Inferenz stellt dabei im Gegensatz zur Deduktion einen erweiternden Schluss dar. Wie diese Erweiterung bzw. Generalisierung aussieht, hängt i. A. vom induktiven Bias eines Lernverfahrens ab, wie z. B. von der Struktur des Raums der möglichen Konzepte. Im Gegensatz zum klassischen Konzeptlernen und der konzeptuellen Clusteranalyse werden in der adaptiven Umweltmodellierung die Werte der Attribute von sowohl Lernbeispielen als auch von zu lernenden Konzepten probabilistisch durch Wahrscheinlichkeitsverteilungen beschrieben. Der zugrunde liegende Raum der möglichen Konzepte wird weiterhin durch die

Definitionen des Metamodells bestimmt. Dort werden strukturelle Annahmen für Konzepte getroffen. Ihre Attribute werden dabei durch ein Skalenniveau und einen Wertebereich beschrieben. Weitere Restriktionen für Attribute werden nicht definiert. Eine Generalisierung von Konzepten kann nun innerhalb dieses grundsätzlichen Konzeptraums erfolgen. Diese Generalisierung beschränkt sich in der adaptiven Umweltmodellierung, ähnlich wie beim klassischen Konzeptlernen, auf die Generalisierung von Attributwerten. Zusätzliche Attribute gegenüber den in der Menge der Lernbeispiele enthaltenen werden nicht definiert. Eine Generalisierung von Attributwerten kann in der adaptiven Umweltmodellierung somit, unter Beachtung des Skalenniveaus und Wertebereichs eines Attributs, flexibel erfolgen.

8.4.1 Allgemeines Vorgehen

Für das Konzeptlernen in der adaptiven Umweltmodellierung ist als Ausgangssituation eine Menge von Repräsentanten als Lernbeispiele gegeben. Für diese Repräsentanten muss nun eine vereinheitlichte und generalisierte Konzeptdefinition gefunden werden, welche alle Repräsentanten zu beschreiben vermag. Dabei wird in der adaptiven Umweltmodellierung jedes Attribut individuell betrachtet. Insgesamt wird in zwei Schritten vorgegangen. Zunächst werden pro Attribut die Wahrscheinlichkeitsverteilungen der Lernbeispiele zu einer aggregierten Verteilung kombiniert. Dies wird in Abschnitt 8.4.2 beschrieben. Anschließend wird, ebenfalls individuell pro Attribut, diese aggregierte Verteilung generalisiert. Dies wird in Abschnitt 8.4.3 beschrieben. Die Darstellung dieser Aspekte basiert auf [Kuw14].

Als Ausgangssituation, vor allem in Bezug auf die individuelle Kombination von Attributen, können dabei zwei Fälle unterschieden werden. Einerseits kann es sein, dass ein gänzlich neues Konzept gelernt werden soll, rein auf Basis der gegebenen Repräsentanten als Lernbeispiele. In diesem Fall müssen pro Attribut nur die Verteilungen aller Lernbeispiele kombiniert werden. Andererseits kann es sein, dass ein existierendes Konzept erweitert werden soll. In diesem Fall ist neben den Lernbeispielen auch noch die Definition des

Konzepts selbst gegeben. Wie vorausgehend bereits erwähnt, sind die Beschreibungen von Repräsentanten und Konzepten über ihre Attributmengen syntaktisch gleichartig. Daher ist es möglich, den Fall der Erweiterung eines existierenden Konzepts auf ähnliche Weise wie den Fall des Erlernens eines neuen Konzepts zu behandeln. Das entsprechende Vorgehen wird nachfolgend vorgestellt.

8.4.2 Lernen von Konzeptdefinitionen aus Beispielen

Aufgrund der syntaktischen Gleichartigkeit von Repräsentanten und Konzepten kann zur Definition eines neuen Konzepts ein einfacher Ansatz gewählt werden. Dieser Ansatz besteht, grob gesagt, aus der Aggregation der unterschiedlichen Attributwerte der als Lernbeispiele gegebenen Repräsentanten $\mathcal{S}_{\mathcal{R}}^*$ durch Mittelung. Bei diesem Ansatz wird zunächst jedes (deskriptive) Attribut $a^{*,i}$ des neu zu definierenden Konzepts individuell betrachtet. Für jedes Attribut müssen nun die Wahrscheinlichkeitsverteilungen $p_{a^{r,i}}(a)$ der Attribute $a^{r,i}$ der Lernbeispiele kombiniert werden. Für ein diskretes Attribut $a^{d,*,i}$ kann dies in Form der normierten Summe

$$p_{a^{d,*,i}}(a) := \frac{1}{|\mathcal{S}_{\mathcal{R}}^*|} \cdot \sum_{r \in \mathcal{S}_{\mathcal{R}}^*} p_{a^{r,i}}(a) \quad (8.22)$$

erfolgen. Für ein stetiges Attribut $a^{c,*,i}$ muss eine derartige Kombination in Form einer Mischverteilung erfolgen, d. h. als

$$p_{a^{c,*,i}}(a) := \sum_{r \in \mathcal{S}_{\mathcal{R}}^*} \frac{1}{|\mathcal{S}_{\mathcal{R}}^*|} \cdot p_{a^{r,i}}(a) . \quad (8.23)$$

Falls eine der stetigen Verteilungen der Lernbeispiele dabei bereits durch eine Mischverteilung beschrieben wird, müssen die Gewichte ihrer Komponenten entsprechend aktualisiert werden mit dem zusätzlichen Gewichtungsfaktor $\frac{1}{|\mathcal{S}_{\mathcal{R}}^*|}$.

Falls nicht ein gänzlich neues Konzept gelernt, sondern ein existierendes Konzept erweitert werden soll, wird der grundsätzlich gleiche Ansatz wie beschrieben gewählt. Zusätzlich geht nun allerdings in die Summen (8.22) und (8.23) jeweils die Verteilung des Konzeptattributs gewichtet mit ein. Über die Gewichtung der Konzeptverteilung gegenüber der Gesamtheit der Verteilungen der Lernbeispiele kann dabei festgelegt werden, wie stark eine existierende Konzeptdefinition auf die neuen Lernbeispiele angepasst werden soll. Eine natürliche Wahl für diese Gewichtung stellt die Anzahl der Lernbeispiele dar, die ursprünglich zur Definition des Konzepts genutzt wurden. Wird ein Konzept z. B. durch den beschriebenen Lernprozess neu definiert, kann zusätzlich zur Beschreibung des Konzepts auch die Anzahl der Lernbeispiele abgespeichert werden, welche zur Definition des Konzepts genutzt wurden. Soll ein solches Konzept dann später erweitert werden, kann diese Anzahl als Gewichtung gegenüber der Anzahl der zur Erweiterung gegebenen Lernbeispiele verwendet werden.

8.4.3 Generalisierung von Konzept-Attributen

Der erste Schritt beim Konzeptlernen in der adaptiven Umweltmodellierung besteht daraus, individuell pro Attribut die Wahrscheinlichkeitsverteilungen der Lernbeispiele zu kombinieren. Als zweiter Schritt soll die resultierende aggregierte Wahrscheinlichkeitsverteilung anschließend noch generalisiert werden. Der Begriff der Generalisierung kann dabei so verstanden werden, dass eine gegebene Attributverteilung durch eine entsprechende Generalisierungsoperation in eine weniger spezifische Version der Verteilung überführt werden soll. Weniger spezifisch bezieht sich in diesem Fall auf die von der Verteilung erlaubten Werte. Im Sinne der Modellbewertung wird durch eine Generalisierung die Komplexität eines Attributs reduziert. Die generellste, am wenigsten komplexe Form einer Attributverteilung ist dabei durch eine Gleichverteilung über dem entsprechenden Wertebereich gegeben. Die Generalisierung einer Attributverteilung transformiert diese somit in eine ähnliche Verteilung in Richtung dieser Gleichverteilung. Auf welche Weise eine Generalisierung genau erfolgen kann, hängt dabei von der dem Wertebereich zugrunde liegenden inneren Struktur der Werte ab. Diese

Struktur wird größtenteils durch das Skalenniveau eines Attributs charakterisiert. Für die Generalisierung von Attributverteilungen müssen somit diskrete von stetigen Attributen unterschieden werden. Für diskrete Attribute müssen weiterhin nominale von ordinal skalierten Attributen unterschieden werden.

In der adaptiven Umweltmodellierung wird eine Generalisierung als zielführend betrachtet, wenn sie eine gegebene Attributverteilung konsistent auf mehr erlaubte Werte erweitert. Dabei liegt die Annahme zugrunde, dass eine Erweiterung der zulässigen Attributwerte einer Verteilung zunächst diejenigen Attributwerte betrachten sollte, welche ähnlich zu den bisher erlaubten Attributwerten sind. Diese Annahme ist, aus didaktischen Gründen, für deterministische Werte formuliert. Sie lässt sich auf probabilistisch beschriebene Werte übertragen, indem die Zulässigkeit von Werten als eine signifikante Wahrscheinlichkeit über diesen Werten interpretiert wird. Eine Grundannahme zur Generalisierung von Attributverteilungen in der adaptiven Umweltmodellierung ist es somit, dass die einzelnen Werte eines Attributs hinsichtlich ihrer Ähnlichkeit zumindest qualitativ bewertet werden können sollten. Dies ist für ordinal und kardinal skalierte Attribute der Fall, für nominale Attribute dagegen nicht. Im klassischen Konzeptlernen nach Mitchell [Mit79] werden nominale Attribute generalisiert, indem das Vorliegen von mindestens zwei unterschiedlichen Werte in den Lernbeispielen als Indikator dafür gedeutet wird, dass jeder Wert des Wertebereichs für dieses Attribut zulässig ist. Diese Annahme wird für die adaptive Umweltmodellierung allerdings als zu stark empfunden. Eine Generalisierung von diskreten Attributen wird daher nur für ordinal skalierte Attribute betrachtet. Für diese wird ihre zugrunde liegende Ordnungsrelation als eine qualitative Ähnlichkeitsbewertung angesehen.

Generalisierung von ordinalen Attributen

Methodisch kann für eine Generalisierung der Wahrscheinlichkeitsverteilung von ordinalen Attributen Inspiration im Bereich der digitalen Bildverarbeitung gefunden werden. Im Speziellen stellen sog. morphologische Operationen auf Grauwertbildern hierbei interessante Ansätze dar. Durch Operationen wie eine Dilatation, Erosion und Schließung kann dabei z. B. erreicht werden, dass Lücken in Grauwertbildern durch eine konsistente Fortsetzung von räumlichen Intensitätsverläufen geschlossen werden.

Ein solches Vorgehen kann nun auf die Generalisierung der kumulierten Wahrscheinlichkeitsverteilungen von ordinalen Konzept-Attributen übertragen werden. Dabei ist es die Intension, die zulässigen Werte einer Verteilung graduell auch auf Teilbereiche auszudehnen, welche eine konsistente Erweiterung der bisher zulässigen Werte darstellen und somit eventuelle, nicht durch die Beispiele abgedeckte Teilbereiche (Lücken) zu füllen. Bei einem solchen Vorgehen wird implizit angenommen, dass diese Lücken nur deswegen nicht bereits durch die Beispiele abgedeckt werden konnten, da als Lerndaten bisher nur eine geringe Menge von Beispielen zur Verfügung stand. Dieses Vorgehen wird in Abbildung 8.6 illustriert. Dargestellt sind Verteilungen für zwei beispielhafte Attribute (links) sowie deren kombinierte Verteilung (rechts oben). Die Verteilung des generalisierten Attributs (rechts unten) ergibt sich dabei durch Anwendung einer Schließungsoperation.

Umgesetzt werden kann dieses Vorgehen für die Generalisierung von ordinalen Attributen in der adaptiven Umweltmodellierung z. B. dadurch, dass ein diskreter normierter Faltungskern über den Wertebereich eines ordinalen Attributs geschoben wird. Dabei wird der Wert der Verteilung am Mittelpunkt des Kerns jeweils durch das Ergebnis der Faltung von Verteilung und Kern ersetzt. Für das gewünschte Verhalten bietet sich z. B. ein diskretisiertes eindimensionales Gaußfilter als Faltungskern an.

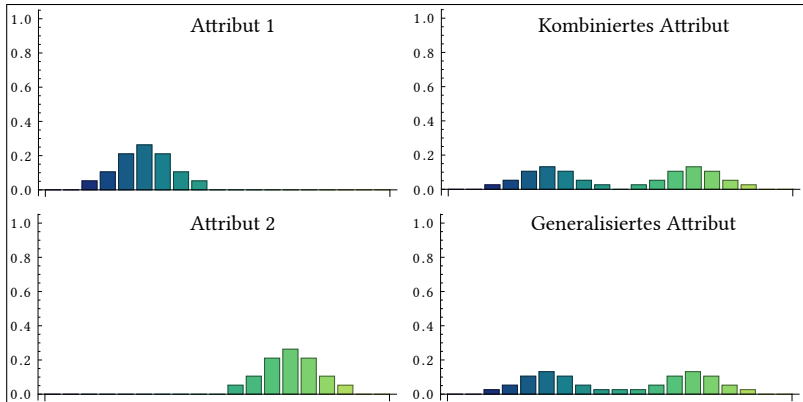


Abbildung 8.6: Beispiel für die Kombination (rechts oben) zweier diskreter Attribute (links) und die Generalisierung (rechts unten) der kombinierten Verteilung für den Fall, dass die Attribute ordinal skaliert sind.

Generalisierung von stetigen Attributen durch Komponentenreduktion

Stetige Attribute werden in der objektorientierten Umweltmodellierung durch Normalverteilungen oder durch Gaußmischverteilungen beschrieben. Durch die Kombination der Wahrscheinlichkeitsverteilungen aller Lernbeispiele für ein betrachtetes stetiges Attribut nach Gleichung (8.23) entsteht somit eine neue Gaußmischverteilung. Als Lernbeispiele werden im vorgestellten Ansatz diejenigen Repräsentanten ausgewählt, die sich möglichst ähnlich sind und für welche angenommen wird, dass sie den gleichen Typ von Entität darstellen. Aufgrund dieser Ähnlichkeit kann für die kombinierte Verteilung angenommen werden, dass im Regelfall viele ähnliche Normalverteilungen (ähnlich z. B. in Bezug auf ihre Position) als Komponenten in der Mischverteilung enthalten sind. Eine derartige Mischverteilung beschreibt die Werte eines Attributs bzgl. der dargestellten Informationen dann auf eine teilweise redundante Weise. Zugleich ist sie aufgrund ihrer Komponentenanzahl sehr komplex. Durch eine Reduktion der Anzahl der enthaltenen Komponenten kann eine solche Verteilung vereinfacht und in ihrer Redundanz reduziert werden, ohne signifikante

Verluste für die dargestellten Informationen befürchten zu müssen. Zugleich kann dabei eine Generalisierung der Verteilung erreicht werden. Bei einer Reduktion der Komponenten einer Mischverteilung werden diese Komponenten sukzessive durch neue, kombinierte Komponenten ersetzt. Eine Generalisierung betrifft dabei den Aspekt, dass durch eine solche Kombination auch neue Komponenten entstehen können, welche mögliche Lücken in einer Verteilung schließen. In der adaptiven Umweltmodellierung können sich derartige Lücken z. B. aufgrund der Werte der Lernbeispiele ergeben. Eine Generalisierung mittels Komponentenreduktion setzt daher das für die Modellanpassung gewünschte Verhalten um, in welchem sich die Generalisierung an den existierenden Werten einer Verteilung orientiert. Diese sind hier in Form der einzelnen Komponenten gegeben.

Für die adaptive Umweltmodellierung können zur Generalisierung von Konzept-Attributen somit Verfahren der Gaußmischreduktion¹ eingesetzt werden. Derartige Verfahren ersetzen für eine Reduktion der Komponentenanzahl sukzessive Komponenten durch eine neue, kombinierte Komponente. In der Literatur existieren verschiedene Ansätze für eine Gaußmischreduktion. Ein grundlegendes, agglomeratives Vorgehen wird von West [Wes93] beschrieben. Es besteht aus den in Algorithmus 2 dargestellten Schritten.

Algorithmus 2 Agglomerative Komponentenreduktion für Gaußmischverteilungen

```
1: # Eingabe: Gaußmischdichte mit  $m$  Komponenten
2: while Abbruchkriterium nicht erreicht do # z. B. Anzahl Komponenten
3:     Finde beste zwei Kandidaten für eine Verschmelzung
4:     Verschmelze und ersetze die Kandidaten durch neue Komponente
5: end while
6: # Ausgabe: Reduzierte Gaußmischdichte mit  $k < m$  Komponenten
```

¹ Englisch: Gaussian mixture reduction

Verschiedene Ansätze zur Gaußmischreduktion unterscheiden sich nun darin, auf welche Weise die beiden Schritte und das Abbruchkriterium umgesetzt werden. Von Runnalls [Run07] und Salmond [Sal09] wird beispielsweise eine Kombination von Komponenten pro Schritt (Zeile 4 in Algorithmus 2) vorgeschlagen, durch welche der Erwartungswert und die Varianz der Gesamtverteilung erhalten bleiben. Für zwei Komponenten $\mathcal{N}(\mu_1, \sigma_1^2)$ und $\mathcal{N}(\mu_2, \sigma_2^2)$ mit den Gewichten w_1 und w_2 kann die kombinierte normalverteilte Komponente $\mathcal{N}(\mu_*, \sigma_*^2)$ mit Gewicht w_* dabei als

$$w_* = w_1 + w_2, \quad (8.24)$$

$$\bar{w}_1 := \frac{w_1}{w_*}, \quad \bar{w}_2 := \frac{w_2}{w_*}, \quad (8.25)$$

$$\mu_* = \bar{w}_1 \mu_1 + \bar{w}_2 \mu_2, \quad (8.26)$$

$$\sigma_*^2 = \bar{w}_1 \sigma_1^2 + \bar{w}_2 \sigma_2^2 + \bar{w}_1 \bar{w}_2 (\mu_1 - \mu_2)^2 \quad (8.27)$$

berechnet werden. Für die Auswahl (Zeile 3 in Algorithmus 2) der pro Schritt zu kombinierenden Komponenten existieren verschiedene Ansätze. Globale Ansätze (z. B. [Run07, Hub08]) orientieren sich dabei z. B. daran, pro Schritt eine möglichst zur Ausgangsverteilung ähnliche reduzierte Mischverteilung zu erzeugen. Zur Bewertung der Ähnlichkeit der Verteilungen können der integrierte quadratische Abstand der Verteilungen [Hub08] bzw. ein Ansatz auf Basis der Kullback-Leibler Divergenz [Run07] verwendet werden. Lokale Ansätze (z. B. [Wes93, Sal09]) versuchen dagegen, in jedem Schritt jeweils möglichst nahe zueinander gelegene Komponenten zu kombinieren. Dabei kann beispielsweise die Komponente mit dem aktuell kleinsten Gewicht mit ihrer nächst gelegenen Komponente (im Sinne einer euklidischen Distanz) kombiniert werden [Wes93]. Von Salmond [Sal09] wird weiterhin die gewichtete Mahalanobis Distanz

$$d_{i,j} := \frac{w_i w_j}{w_i + w_j} \frac{(\mu_i - \mu_j)^2}{\sigma_m^2} \quad (8.28)$$

zweier Komponenten i und j genutzt, um in jedem Schritt die zwei paarweise nächst gelegenen Komponenten zu bestimmen. Dabei beschreibt σ_m^2 die Varianz der gesamten Mischverteilung.

Als ein übliches Abbruchkriterium (Zeile 2 in Algorithmus 2) kann die gewünschte Anzahl von in der Verteilung verbleibenden Komponenten vorgegeben werden [Wes93, Run07]. Weiterhin kann auch eine maximal erlaubte Abweichung der reduzierten Verteilung von der ursprünglichen Mischverteilung als ein Abbruchkriterium genutzt werden [Hub08]. Ein solches Abbruchkriterium ist dabei für die Generalisierung der Verteilungen von Konzept-Attributen in der adaptiven Umweltmodellierung besonders interessant, da eine gewünschte Anzahl von Komponenten für Attributverteilungen hier teilweise nur schwer vorhergesagt werden kann.

Zur Bewertung der Ähnlichkeit einer reduzierten Verteilung gegenüber der ursprünglichen kombinierten Mischverteilung eines Konzept-Attributs stellt weiterhin die Kullback-Leibler Divergenz ein geeignetes Maß dar (vgl. [Hub08]). Die Berechnung der Kullback-Leibler Divergenz muss dabei allerdings numerisch erfolgen, da für Gaußmischverteilungen keine geschlossene Lösung angegeben werden kann [Hub08]. Für die Auswahl der pro Schritt zu kombinierenden Komponenten bietet sich für die adaptive Umweltmodellierung ein lokaler Ansatz an. Durch einen lokalen Ansatz kann der beschriebene Generalisierungseffekt besser erreicht werden, indem sichergestellt wird, dass immer zuerst nahe gelegene, benachbarte Komponenten kombiniert werden. Zu diesem Zweck kann die gewichtete Mahalanobis Distanz (8.28) eingesetzt werden. Die Mahalanobis Distanz bietet weiterhin den Vorteil, dass sie ein skalierungsinvariantes Maß darstellt [Sal09]. Dies ist z. B. vorteilhaft, wenn stetige Attribute in unterschiedlichen Maßeinheiten gegeben sind. Für die Kombination zweier derart ausgewählter Komponenten wird in der adaptiven Umweltmodellierung schließlich der oben beschriebene Ansatz von Runnalls [Run07] bzw. Salmond [Sal09] genutzt.

Unter diesen drei Festlegungen kann Algorithmus 2 zur Generalisierung der Gaußmischverteilungen von kombinierten Konzept-Attributen eingesetzt werden. Dabei werden in jedem Schritt des Algorithmus zwei

Komponenten der Mischverteilung durch eine neue normalverteilte Komponente approximiert. Pro Schritt erhöht sich somit in der Regel die über die Kullback-Leibler Divergenz bewertete Distanz zur ursprünglichen Mischverteilung des Attributs. Dies wird so lange fortgesetzt, bis sich die reduzierte Verteilung aufgrund der wiederholten Approximationen zu stark von der ursprünglichen Mischverteilung unterscheidet. Dabei muss ein Schwellwert für den maximal erlaubten Unterschied festgelegt werden, bei welchem die Generalisierung abbrechen ist.

Grundsätzlich sollte dieser maximal erlaubte Unterschied der reduzierten Verteilung dabei nicht zu groß gewählt werden. Die zugrunde liegende Idee der Generalisierung ist es zu versuchen, Lücken in der Verteilung zu schließen, für welche keine Lernbeispiele vorliegen. Allerdings sollten dabei nicht notwendigerweise systematische Lücken geschlossen werden. Systematische Lücken in Attributverteilungen können z. B. dadurch bedingt sein, dass Entitäten eines Typs Attributwerte in verschiedenen Bereichen annehmen, aber nicht zwischen diesen Bereichen. Dies kann der Fall sein, wenn abstraktere Konzepte betrachtet werden, wie z. B. der allgemeine Begriff Löffel und dessen Qualität Länge. Aufgrund unterschiedlicher Unterklassen wie Kaffeelöffel oder Eszlöffel gibt es hier z. B. zwei unterschiedliche Längenbereiche, deren Lücke durch eine Generalisierung nicht notwendigerweise geschlossen werden soll. Abbildung 8.7 stellt einen solchen Fall abstrahiert dar und illustriert zugleich die Reduktion von Gaußmischdichten.

Ein Schwellwert als Abbruchkriterium der Komponentenreduktion sollte i. A. also so gewählt werden, dass systematische Lücken in den Wertebereichen eines Attributs erhalten bleiben, kleinere, durch fehlende Lernbeispiele verursachte Lücken aber geschlossen werden. Dies ist nicht immer einfach. Vorteilhaft für die Wahl eines Schwellwerts ist dabei, dass eine Bewertung der Unterschiedlichkeit von reduzierter und ursprünglicher Verteilung mittels Kullback-Leibler Divergenz nicht von der Skalierung der Attribute abhängt. Allerdings kann sich ein gewünschtes Generalisierungsergebnis abhängig davon unterscheiden, wie spezifisch ein Konzept ist. Für Konzepte, welche einen sehr spezifischen Typ von Entität beschreiben, kann dabei eine unterschiedlich starke Generalisierung gewünscht sein als für Konzepte,

welche eher abstrakte, aggregierende Entitätenstypen beschreiben. Für neu gelernte Konzepte wird dabei zunächst davon ausgegangen, dass ein spezifischer Typ von Entität repräsentiert werden soll. Weiterhin kann die Wahl eines Schwellwerts auch von der betrachteten Qualität eines Attributs und deren Bedeutung in einem Anwendungsfall abhängen.




Abbildung 8.7: Beispiel für die Komponentenreduktion einer Gaußmischverteilung. Die ursprüngliche Mischverteilung (blau) mit drei normalverteilten Komponenten wird dabei durch Zusammenfassung der Komponenten auf eine Verteilung mit zwei (violett) bzw. einer (beige) Komponenten reduziert. Die Reduktion auf eine einzige Komponente kann dabei für Konzept-Attribute in bestimmten Situationen, z. B. für abstraktere Konzepte, unerwünscht sein, da durch die resultierende Komponente auch ein Bereich von Werten in der Mitte der Verteilung enthalten ist, welcher nicht durch Beispiele gestützt wird. Für spezifische Konzepte kann eine solche Schließung von Lücken dagegen gerade als ein Generalisierungseffekt erwünscht sein.

In [Kuw14] wurden beispielhaft die Auswirkungen der Generalisierung von Attributen mittels Komponentenreduktion auf die zu definierenden Konzepte untersucht. Dabei wurde betrachtet, wie sich unterschiedlich starke Reduktionen (gemessen in der Anzahl der verbleibenden Komponenten) auf relevante Eigenschaften von Konzept-Attributen für die Umweltmodellierung auswirken. Konkret wurde dabei die Verwendung der generalisierten Attribute in der Repräsentant-zu-Konzept Zuordnung, in Form von attributbasierten Zuordnungswerten, sowie in der quantitativen Modellbewertung,

in Form von attributbasierten Korrespondenzwerten, betrachtet. Zu diesem Zweck wurden zum Vergleich unterschiedliche Verteilungen für beispielhafte Repräsentanten-Attribute genutzt. Dies waren zunächst Verteilungen, welche bereits von einzelnen Komponenten der ursprünglichen Verteilung des Konzept-Attributs abgedeckt werden konnten. Weiterhin wurden auch Verteilungen genutzt, welche entweder in entsprechende Lücken der ursprünglichen Verteilung fielen oder in benachbarten Bereichen lagen. Dabei konnte demonstriert werden, dass mit fortschreitender Reduktion z. B. die Zuordnung von in Lücken gelegenen Repräsentanten-Attributen zum Konzept-Attribut verbessert wird. Ebenso nimmt für diese die notwendige Beschreibung ab, wenn das reduzierte Konzept-Attribut als Modell genutzt wird. Wird keine zu starke Reduktion (z. B. auf nur eine verbleibende Komponente) durchgeführt, konnte das benachbarte Repräsentanten-Attribut weiterhin (z. B. durch die Repräsentant-zu-Konzept Zuordnung) ausreichend gut vom reduzierten Konzept-Attribut unterschieden werden. Weitere Einzelheiten dieser Betrachtung sind in [Kuw14] gegeben.

Ein Beispiel dafür, wie ein neues Konzept auf Basis von schlecht beschriebenen Repräsentanten als Lernbeispielen definiert und verallgemeinert werden kann, wird im nachfolgenden Abschnitt im Rahmen des komplexeren Anwendungsszenarios gegeben.

Der Ansatz der Generalisierung über eine Komponentenreduktion ist ein einfacher Ansatz für die adaptive Umweltmodellierung. Der Vorteil dieses Ansatzes ist dabei, dass er sich gut in die objektorientierte Umweltmodellierung mit ihrer Informationsrepräsentation für stetige Attribute durch Normalverteilungen und Gaußmischverteilungen einfügt. Insgesamt sind allerdings auch andere Ansätze zur Vereinfachung und Generalisierung der Mischverteilungen denkbar, z. B. unter Betrachtung und Approximation der Verteilungsfunktion der Mischverteilung.

8.5 Evaluation des Gesamtansatzes

Zur Evaluation des Gesamtansatzes der adaptiven Umweltmodellierung samt adaptiver Modellverwaltung wurde ein zweites, komplexeres Evaluationsszenario betrachtet und definiert. In diesem Szenario wird wieder eine Haushaltsumgebung als Anwendungsdomäne betrachtet, in welcher ein humanoider Roboter Menschen bei der Durchführung von Alltagsaufgaben unterstützt. Im Vergleich zum bisher beschriebenen einfachen Demonstrationsszenario wird nun allerdings eine deutlich größere Anzahl an Konzepten im Hintergrundwissen betrachtet. Weiterhin werden die Konzepte über eine größere Anzahl an realistischeren Attributen beschrieben. Dennoch stellt auch dieses Evaluationsszenario nur einen abstrahierten Ablauf mit synthetischen Beobachtungen dar und verwendet keine echten Sensordaten eines technisch kognitiven Systems. Das Szenario und die entsprechende Evaluation wurde größtenteils in [Kuw16] vorgestellt.

8.5.1 Evaluationsszenario

Dem Szenario liegt der nachfolgend dargestellte, hypothetische Ablauf zugrunde. Als technisch kognitives System wird ein humanoider Roboter betrachtet, welcher eine Küche betritt. Dort beobachtet der Roboter verschiedene Alltagsgegenstände, darunter Möbel wie einen Tisch und vier Stühle sowie einen Kühlschrank. Da der Tisch relevant für die Aufgaben des Roboters ist, nähert er sich diesem und inspiziert ihn genauer. Auf dem Tisch befinden sich Teller, Tafelmesser sowie eine Schale mit verschiedenen Obstsorten. Daraufhin betritt ein Mensch die Küche und beginnt, den Tisch weiter zu decken. Der Roboter beobachtet nun weiteres Geschirr wie Untertassen und Tassen sowie weiteres Besteck wie Gabeln und Löffel. Auch weitere Obstsorten werden beobachtet.

Im beschriebenen Ablauf werden insgesamt 29 unterschiedliche Objekte beobachtet, welche 17 unterschiedlichen Typen von Entitäten angehören. Dabei sind 13 Konzepte als Vorwissen bereits im Hintergrundwissensmodell probabilistisch modelliert. Nicht enthalten sind Konzepte für Teller sowie

für Orangen und Trauben. Beobachtete Instanzen dieser Typen stellen im Weltmodell also schlecht beschriebene Repräsentanten dar.

Die modellierten Konzepte stellen dabei eine Teilmenge derjenigen Blattknoten dar, welche im in Abschnitt 4.6 beschriebenen hierarchischen Domänenmodell für die Haushaltsdomäne relational modelliert wurden. Somit wird mittels dieses Evaluationsszenarios auch ein Beispiel für die probabilistische Modellierung der entsprechenden Konzepte gegeben.

Repräsentation von Konzepten

Zur Beschreibung der Repräsentanten und Konzepte im komplexeren Evaluationsszenario werden insgesamt zwölf Attribute verwendet, die unterschiedliche Qualitäten repräsentieren. Als in ihrer Bedeutung interpretierbare stetige Attribute werden dabei die Abmessungen von Objekten betrachtet, in Form ihrer Länge, Breite und Höhe, sowie vier subsymbolische Formfaktoren. Als interpretierbare diskrete Attribute werden eine symbolische Formbeschreibung sowie die Farbe und das Material von Objekten betrachtet. Für die Qualitäten Farbe und Material sind dabei jeweils zwei Attribute definiert, welche die Primär- und Sekundärfarbe eines Objekts bzw. dessen Primär- und Sekundärmaterial repräsentieren. Diese Menge von Attributen wurde ausgewählt, da für sie unter Verwendung von Techniken des maschinellen Sehens aus entsprechenden Bilddaten, z. B. in Verbindung mit entsprechenden 3D-Informationen, Werte automatisiert abgeleitet werden können. Folglich wurden auch für die Definition des Evaluationsszenarios die Attributwerte einiger Repräsentanten und Konzepte bzgl. ihrer Qualitäten Farbe (mit Primär- und Sekundärfarbe) und Form (symbolisch und als Formfaktor) aus ausgewählten Beispielbildern automatisch extrahiert. Als Vorverarbeitung wurde dabei zunächst eine semi-automatische Objektsegmentierung durchgeführt.

Probabilistische Modellierung von Konzept-Attributen

Zur Modellierung der probabilistischen Attribute von Konzepten als Vorwissen wurde der bereits in Kapitel 4.5.2 erwähnte Ansatz einer stichprobenbasierten Definition der Verteilungen gewählt. Für eine Analyse der Attributwerte der Konzepte wurde daher zunächst pro Attribut und Konzept eine größere Menge von Beispielwerten ermittelt. Dabei wurden z. B. Produktbeschreibungen und eigene Messungen für die Attribute zu den Qualitäten der Abmessungen und des Materials von Objekten verwendet. Weiterhin wurde das beschriebene Vorgehen auf Basis des maschinellen Sehens für die farb- und formbezogenen Qualitäten genutzt.

Primär- und Sekundärfarbe Die Attribute Primär- und Sekundärfarbe wurden im Evaluationsszenario als diskrete nominale Attribute über dem symbolischen Wertebereich $\mathcal{S}_{\text{Farbe}} := \{ \text{rot, orange, gelb, grün, blau, violett, braun, schwarz, grau, silber, weiß, transparent} \}$ definiert. Zur Modellierung der Attributverteilungen für jedes der 13 zu definierenden Konzepte wurde zunächst eine Stichprobe von Beispielobjekten erstellt. Die Werte für jedes dieser Beispielobjekte wurden nach einem gemischten Vorgehen in Abhängigkeit des Typs des Objekts ermittelt. Für menschgemachte Objekte (wie Möbel, Geschirr, Besteck etc.) wurden die beiden Farbwerte manuell auf Basis von Produktbeschreibungen als deterministische Werte ermittelt. Für natürliche Objekte (wie Obstsorten) wurden die Werte dagegen mit Methoden der digitalen Bildverarbeitung auf Basis von Beispielbildern ermittelt. Dazu wurden auf einem semi-automatisiert segmentierten Bild die zwei dominantesten Farben für ein Objekt bestimmt und als Werte im HSB-Farbraum dargestellt. Jeder dieser Werte wurde anschließend auf den symbolischen Wertebereich $\mathcal{S}_{\text{Farbe}}$ abgebildet. Dazu wurde über einen funktionalen Zusammenhang für jede symbolische Farbe des Wertebereichs ihr Anteil im abzubildenden Farbwert berechnet. Durch Normierung ergab sich für jedes Beispielobjekt schließlich eine diskrete Verteilung über $\mathcal{S}_{\text{Farbe}}$.

Zur Berechnung der Verteilungen der beiden Konzept-Attribute aus diesen Verteilungen für die Beispielobjekte wurde ein Vorgehen analog zum Ansatz für das Lernen von Konzeptdefinitionen in Abschnitt 8.4.2 gewählt. Dazu wurden die Verteilungen aller Beispielobjekte als eine normierte Summe (vgl. (8.22)) kombiniert. Eine Generalisierung für die diskreten Farbattribute erfolgte im Evaluationsszenario nicht.

Primär- und Sekundärmaterial Die Attribute Primär- und Sekundärmaterial wurden im Evaluationsszenario als diskrete nominale Attribute über dem symbolischen Wertebereich $S_{\text{Material}} := \{ \text{Holz}, \text{Glas}, \text{Metall}, \text{Leder}, \text{Plastik}, \text{Porzellan}, \text{Organisches} \}$ definiert. Die Attributverteilungen für die zu definierenden Konzepte wurden analog zum Vorgehen bei den Farbattributen für menschgemachte Objekte bestimmt. Dazu wurden pro Konzept für verschiedene Beispielobjekte deterministische Werte auf Basis von Produktbeschreibungen bestimmt und diese zur Beschreibung des Konzept-Attributs in Form einer Häufigkeitsverteilung kombiniert. Auch für diese diskreten Attribute erfolgte im Evaluationsszenario keine Generalisierung.

Form-Attribute Zur Beschreibung der Form von Objekten wurde im Evaluationsszenario ein diskretes nominales Form-Attribut mit Wertebereich $S_{\text{Form}} := \{ \text{Ellipse3}, \text{Rechteck1}, \text{Ellipse2}, \text{Kreis}, \text{Ellipse0}, \text{Rechteck2}, \text{Ellipse1} \}$ definiert. Die verschiedenen Symbole für Ellipsen und Rechtecke beschreiben dabei jeweils unterschiedliche Orientierungen dieser Grundformen. Die Verteilung dieses Attributs für die zu definierenden Konzepte wurde analog zum Vorgehen bei Farbattributen als eine normierte Summe über den individuellen Verteilungen von Beispielobjekten berechnet. Die Verteilungen für Beispielobjekte, welche in segmentierten Bildern gegeben waren, wurden unter Verwendung verschiedener formbezogener Maßzahlen der digitalen Bildverarbeitung automatisiert berechnet. Dabei wurde bewertet, zu welchem Anteil ein Objekt den durch die Symbole des Wertebereichs beschriebenen (orientierten) Formen ähnelt. Diese Anteile ergaben nach Normierung die diskrete Attributverteilung pro Objekt.

Weiterhin wurden vier stetige Formfaktoren definiert, welche Werte aus dem Intervall $[0,1]$ annehmen können. Die Werte für diese Formfaktoren wurden ebenfalls automatisiert auf Basis von Beispielbildern ermittelt. Die

Formfaktoren unterteilen ein segmentiertes Objekt in konzentrische Ringscheiben gleicher Breite aber unterschiedlichen Abstands vom Objektmittelpunkt. Dabei wird bewertet, wie viele der Pixel in einer solchen Ringscheibe jeweils vom segmentierten Objekt eingenommen werden. Diese Formfaktoren stellen somit rotations- und skalierungsinvariante Merkmale dar.

Zur Berechnung der stetigen Attributverteilungen für die zu definierenden Konzepte müssen diese Formfaktoren nun ebenfalls zu einer Wahrscheinlichkeitsverteilung kombiniert werden. Dabei wird nach dem Prinzip der Kerndichteschätzung unter Verwendung von Gaußkernen vorgegangen. Für jedes zu einem Konzept gehörende Beispielobjekt wird dazu ein Gaußkern in eine Mischverteilung eingefügt, dessen Mittelwert dem ermittelten Formfaktor entspricht. Dabei wird für den Extraktionsprozess der Formfaktoren im Evaluationsszenario eine Messunsicherheit angenommen, deren Standardabweichung im einstelligen Prozentbereich liegt. Diese Messunsicherheit wurde als Breite der Gaußkerne verwendet.

Die sich durch die derartige Kombination der Formfaktorwerte ergebende Gaußmischverteilung wird anschließend durch eine Komponentenreduktion generalisiert (vgl. Abschnitt 8.4.3). Dabei konnte für die meisten der betrachteten Konzepte eine reduzierte Verteilung mit 1 bis maximal 2 Komponenten je Formfaktor-Attribut erzeugt werden, welche der ursprünglichen Mischverteilung noch hinreichend ähnlich war.

Objektabmessungen Zur Beschreibung der Abmessungen von Objekten durch ihre Länge, Breite und Höhe wurde jeweils ein Wertebereich von 0-300 cm angenommen. Die Werte für die Beispielobjekte pro Konzept wurden hier ebenfalls aus Produktbeschreibungen entnommen. Zur Erzeugung der kombinierten Verteilung aus den Werten der Beispielobjekte wurde derselbe Ansatz wie für die Formfaktoren verwendet. Als Breite der Gaußkerne wurden hier Abweichungen im einstelligen Zentimeterbereich angenommen. Auch diese Konzept-Attribute wurden nach dem in Abschnitt 8.4.3 vorgeschlagenen Ansatz generalisiert. In Abhängigkeit der Spezifität eines Konzepts ergaben sich für die Generalisierung unterschiedliche Ergebnisse, was die Anzahl der in der reduzierten Verteilung verbleibenden Komponenten betraf. Gerade die Konzepte für stärker heterogene Objekttypen wie Tische

oder Kühlschränke mussten dabei in ihren Abmessungen über eine höhere Anzahl an Komponenten beschrieben werden. Abbildung 8.8 stellt beispielhaft die sich nach der Generalisierung ergebenden Verteilungen für die Breite von Tischen und die Höhe von Kühlschränken dar. Bei der Festlegung des Schwellwerts zum Abbruch der Komponentenreduktion muss dabei ein Kompromiss zwischen Generalisierungsfähigkeit des Konzept-Attributs und Spezifität seiner Beschreibung getroffen werden.





Abbildung 8.8: Modellierte Verteilungen für die Breite eines Konzepts *Tisch* und die Höhe eines Konzepts *Kühlschrank*. Die Verteilungen wurden mittels des Ansatzes einer Kerndichteschätzung als Mischverteilungen erzeugt und anschließend mit dem beschriebenen Generalisierungsansatz durch Komponentenreduktion verallgemeinert.

Festlegung von A-priori-Verteilungen

Auf Basis der modellierten Konzepte können nun pro Qualität A-priori-Verteilungen definiert werden, wie sie z. B. in der erweiterten alternativen Repräsentant-zu-Konzept Zuordnung (vgl. Abschnitt 6.4) eingesetzt werden. Für das Evaluationsszenario wurde für stetige Attribute dazu eine normierte Summenverteilung über alle modellierten Konzept-Attribute der entsprechenden Qualität erzeugt und anschließend generalisiert. Abbildung 8.9 zeigt die resultierenden generalisierten Gaußmischverteilungen für die Qualitäten Länge und Breite. Als Abbruchkriterium der Komponentenreduktion wurde hierbei ein disjunktives Kriterium aus minimaler verbleibender Komponentenanzahl und maximaler Abweichung von der ursprünglichen Verteilung gewählt. Für diskrete Attribute wurden entweder

eine Gleichverteilung über dem entsprechenden Wertebereich oder eine normierte Summenverteilung ohne Generalisierung als A-priori-Verteilung genutzt.



(a) A-priori-Verteilung für die Qualität Länge (b) A-priori-Verteilung für die Qualität Breite

Abbildung 8.9: Durch Generalisierung erzeugte A-priori-Verteilungen für die Qualitäten Länge und Breite, wie sie im komplexeren Evaluationsszenario genutzt werden. Dazu wurde zunächst über die Attributverteilungen aller Konzepte für die entsprechende Qualität eine normierte Summe gebildet, welche anschließend durch Komponentenreduktion generalisiert wurde.

Simulationsparameter des Evaluationsszenarios

Das Szenario wurde über 43 Zeitschritte simuliert, wobei sich der Ablauf abstrahiert wie oben beschrieben ergibt. Als initiales Hintergrundwissen wurde die Menge

$$C := \{ \text{Tisch, Stuhl, Kühlschrank, Tasse, Untertasse, Löffel, Gabel, Messer, Apfel, Banane, Birne, Erdbeere, Kokosnuss} \}$$

der 13 definierten Konzepte verwendet. Zu jedem Zeitpunkt wird die Beobachtung von maximal einer Entität verarbeitet. Dabei werden analog zum bisherigen Vorgehen größtenteils Zeitschritte dargestellt, in welchen neue Repräsentanten ins Weltmodell aufgenommen werden. Weiterhin sind zum Teil auch Zeitschritte im Szenario enthalten, in welchen keine Beobachtungen gemacht werden. Im Zeitschritt $t = 1$ wird z. B. keine Entität beobachtet und das Weltmodell enthält dementsprechend noch keine Repräsentanten.

Anschließend werden in den nächsten Zeitschritten analog zum beschriebenen Ablauf folgende Objekte beobachtet:

- ein Tisch ($t = 2$),
- vier Stühle ($t = 3, 4, 6, 7$),
- ein Kühlschrank ($t = 9$),
- zwei Teller ($t = 11$, *Teller-1* und $t = 14$, *Teller-2*),
- zwei Messer ($t = 12, 15$),
- zwei Äpfel ($t = 17, 22$),
- eine Birne ($t = 18$),
- drei Bananen ($t = 19, 23, 24$),
- eine Orange ($t = 21$, *Orange-1*),
- zwei Tassen ($t = 26, 27$),
- zwei Untertassen ($t = 29, 30$),
- zwei Löffeln ($t = 32, 33$),
- zwei Gabeln ($t = 35, 36$),
- zwei Orangen ($t = 38$, *Orange-1'* und $t = 39$, *Orange-2*) und
- zwei Trauben ($t = 41$, *Traube-1* und $t = 42$, *Traube-2*).

Schlecht beschriebene Repräsentanten in Bezug auf die Konzeptmenge \mathcal{C} sind in obiger Aufzählung explizit benannt und angegeben. Sie treten in den Zeitschritten $t = 11, 14, 21, 38, 39, 41$ und $t = 42$ auf. Im Zeitschritt $t = 43$ wird eine Modellanpassung durchgeführt und ein neu gelerntes Konzept (für Orangen) in das Hintergrundwissen \mathcal{C} aufgenommen.

Als ein weiterer Parameter des Evaluationsszenarios wurde der Ansatz der Post-Skalierung nach Gleichung (6.10) zur Berechnung der Repräsentanzu-Konzept Zuordnung verwendet. Weiterhin wurde für die Diskretisierung stetiger Attribute als kleinster unterscheidbarer Betrag ein Wert von $\Delta = 1$ cm für Objektmessungen und von $\Delta = 0.025$ für Formfaktoren genutzt.

8.5.2 Ergebnisse

Für das komplexere Evaluationszenario wurde über den Verlauf der 43 Zeitschritte die Modellgüte bewertet, die jeweils beobachteten Repräsentanten Konzepten zugeordnet sowie schlecht beschriebene Repräsentanten detektiert und gespeichert. Schließlich wurde die Notwendigkeit einer Modellanpassung festgestellt und diese durchgeführt.

Quantitative Modellbewertung

Die Ergebnisse der quantitativen Modellbewertung sind in Abbildung 8.10 dargestellt. Dabei ist als Erstes zu erkennen, dass die Konzeptdefinitionen mit einer realistischeren Anzahl an Attributen deutlich höhere Komplexitätswerte erreichen als im einfachen Demonstrationszenario. Die Werte liegen dabei um bis zu zwei Größenordnungen höher. Beispielwerte für ausgewählte Konzepte sind in Tabelle 8.1 dargestellt.

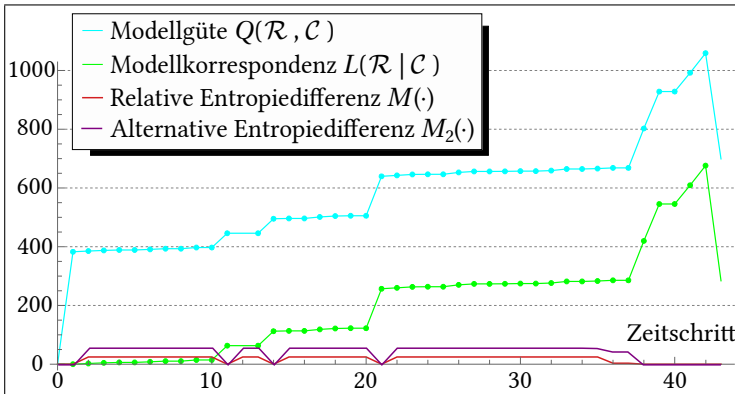


Abbildung 8.10: Ergebnisse der quantitativen Modellbewertung und Detektionsmaße im komplexeren Evaluationszenario über 43 Zeitschritte.

Tabelle 8.1: Komplexitätswerte für vier ausgewählte Konzepte im komplexeren Evaluations-szenario.

Konzept	Komplexität
<i>Tisch</i>	23.4
<i>Untertasse</i>	30.5
<i>Erdbeere</i>	31.8
<i>Gabel</i>	35.4

Neben der Konzeptkomplexität steigen aufgrund der komplexeren Modellierung in Abbildung 8.10 auch die Korrespondenzwerte von Repräsentanten zu Konzepten an. Dabei erhöht sich die Beschreibungslänge für Repräsentanten unter Verwendung der Konzepte als Modelle analog zur Konzeptkomplexität bei einer gesteigerten Anzahl an verwendeten Attributen. Unabhängig von dieser höheren Skalierung der Modellgüte verlaufen die beiden dargestellten Gütemaße der quantitativen Modellbewertung ähnlich wie im einfachen Demonstrationsszenario. Somit skaliert die quantitative Modellbewertung auch für das komplexere Szenario gut. Über die ersten zehn Zeitschritte ist dabei ein leichtes Ansteigen des Modellgütemaßes zu erkennen, verursacht jeweils durch die zusätzlich notwendige Beschreibung für den aktuell beobachteten, gut durch das Hintergrundwissen beschriebenen Repräsentanten. Ähnliches gilt für die weiteren Zeitschritte, in welchen keine schlecht beschriebenen Repräsentanten vorliegen.

Detektion schlecht beschriebener Repräsentanten

Abbildung 8.10 zeigt ebenfalls die Werte der relativen Entropiedifferenz $M(\cdot)$ als Detektionsmaß für schlecht beschriebene Repräsentanten sowie des alternativen Detektionsmaßes $M_2(\cdot)$. In den Zeitschritten $t = 11,14,21$ werden die ersten drei schlecht beschriebenen Repräsentanten durch beide Detektionsmaße erkannt. Dies ist in der Abbildung jeweils durch einen Ausschlag der Maße gegen 0 zu erkennen. Die dargestellten Werte des normierten alternativen Detektionsmaßes $M_2(\cdot)$ sind in der Abbildung aus Gründen der Erkennbarkeit mit einem Faktor von 25 skaliert. Auch die am Ende des

Szenarios in den Zeitschritten $t = 38, 39, 41, 42$ auftretenden schlecht beschriebenen Repräsentanten können detektiert werden. Für die direkt davor in Zeitschritt $t = 36$ beobachtete zweite Gabel (*Gabel-2*) ist eine Unterscheidung auf Basis der relativen Entropiedifferenz $M(\cdot)$ allerdings schwieriger. Durch das alternative Detektionsmaß $M_2(\cdot)$ ist diese Unterscheidung dagegen deutlich einfacher. Insgesamt ergibt sich als Detektionsergebnis im Zeitschritt $t = 42$ die Liste von schlecht beschriebenen Repräsentanten als

$$\mathcal{S}_{\mathcal{R}} = \{\textit{Teller-1}, \textit{Teller-2}, \textit{Orange-1}, \textit{Orange-2}, \textit{Orange-1}', \textit{Traube-1}, \textit{Traube-2}\}.$$

Modellanpassung

Im Zeitschritt $t = 42$ überschreitet der Wert der Modellgüte den Schwellwert für eine tolerierbare Zunahme. In Folge dessen wird eine Modellanpassung angestoßen auf Basis der gespeicherten schlecht beschriebenen Repräsentanten $\mathcal{S}_{\mathcal{R}}$. Dazu wird zunächst einer dieser Repräsentanten als der Kandidat s^* für eine Modellanpassung ausgewählt. Dies kann über eine Bewertung der Relevanz (8.19) aller schlecht beschriebenen Repräsentanten oder über die Bewertung ihrer geschätzten Nützlichkeit (8.20) erfolgen. Die Ergebnisse für beide Ansätze im Evaluationsszenario sind in Tabelle 8.2 dargestellt.

Tabelle 8.2: Relevanz und prädizierte Nützlichkeit von schlecht beschriebenen Repräsentanten im komplexeren Evaluationsszenario. Fett dargestellt ist der jeweils am besten bewertete Repräsentant, welcher als Kandidat s^* für eine Modellanpassung ausgewählt wird.

Repräsentant	Relevanz	Nützlichkeit
<i>Teller-1</i>	2	96.4
<i>Teller-2</i>	2	95.3
<i>Orange-1</i>	3	275.4
<i>Orange-2</i>	3	143.4
<i>Orange-1'</i>	3	275.4
<i>Traube-1</i>	2	141.2
<i>Traube-2</i>	2	139.1

In beiden Ansätzen wird der Repräsentant *Orange-1* als Kandidat s^* ausgewählt. Als Schwellwert für die Relevanzbewertung wurde dabei ein Vielfaches der durchschnittlichen Konzeptkorrespondenz für die bisher beobachteten gut beschriebenen Repräsentanten gewählt. Konkret wurde das Zehnfache genutzt, womit sich $\Phi_s^L = 23.6$ ergibt. Für diesen Kandidaten-Repräsentanten müssen nun weiterhin Lernbeispiele gefunden werden. Unter Anwendung des vorgeschlagenen Vorgehens (8.21) ergibt sich dabei die Menge

$$S_{\mathcal{R}}^* = \{ \textit{Orange-1}, \textit{Orange-2}, \textit{Orange-1}' \} ,$$

wobei zur Bewertung der Ähnlichkeit von Repräsentanten eine Zuordnung nach dem Ansatz der Prä-Skalierung (6.9) genutzt wurde. Dabei wurde ein Schwellwert von $\Phi_s^P = 0.75$ verwendet. Dieser Schwellwert beschreibt beim Ansatz der Prä-Skalierung ein Vielfaches des kombinierten Basiswerts der Zuordnung. Die gewählten Lernbeispiele dienen dann als Grundlage, um mit dem in Abschnitt 8.4 beschriebenen Vorgehen ein neues Konzept zu erlernen. Für die Generalisierung der stetigen Attribute wird dabei ein Schwellwert von 1 (maximale Kullback-Leibler Divergenz zur ursprünglichen Mischverteilung) als Abbruchkriterium der Komponentenreduktion genutzt. Dieses neu erlernte Konzept wurde in Zeitschritt $t = 43$ der Konzeptmenge \mathcal{C} hinzugefügt. In Abbildung 8.10 ist zu erkennen, dass durch diese Modellanpassung eine signifikante Verbesserung der Modellgüte erreicht werden kann (durch das Absinken der Modellgütewerte). Das neu erlernte Konzept trägt dabei mit einer Konzeptkomplexität von 32.2 zur neuen Modellkomplexität bei.

Betrachtung der Repräsentant-zu-Konzept Zuordnung

Die Repräsentant-zu-Konzept Zuordnung stellt einen wichtigen Bestandteil der Verfahren der quantitativen Modellbewertung und der adaptiven Wissensverwaltung dar, z. B. als Ausgangswert für Detektionsmaße. Daher soll diese Zuordnung auch im komplexeren Evaluationsszenario nochmals genauer betrachtet und evaluiert werden.

Abbildung 8.11 stellt zu diesem Zweck Zuordnungsergebnisse für unterschiedliche Repräsentanten des komplexeren Szenarios dar. In den beiden Teilabbildungen 8.11a und 8.11b sind die Zuordnungsverteilungen für zwei Repräsentanten dargestellt, für welche Konzepte im Hintergrundwissen enthalten sind. Beide Repräsentanten werden wie gewünscht eindeutig zugeordnet. In den nächsten beiden Teilabbildungen 8.11c und 8.11d sind Zuordnungsverteilungen für schlecht beschriebene Repräsentanten dargestellt. Auch diese fallen im komplexeren Evaluationsszenario wie gewünscht inkonklusiv aus. In den beiden Teilabbildungen 8.11e und 8.11f sind die Zuordnungsverteilungen für zwei Gabeln dargestellt. Dabei ist zu erkennen, dass die Zuordnung von *Gabel-2* nicht mehr so eindeutig ist wie dies für andere Repräsentanten der Fall war. *Gabel-2* ist auch derjenige Repräsentant, für welchen die relative Entropiedifferenz als Detektionsmaß in Zeitschritt $t = 36$ Schwierigkeiten hatte.

Begründet liegt dieses schlechtere Zuordnungsergebnis darin, dass sich die verschiedenen Konzepte für Besteck (*Löffel*, *Gabel*, *Messer*) sehr stark in ihrer Definition ähneln, und eine Unterscheidung aufgrund von Attributverteilungen in diesem Fall schwierig sein kann. Eine solche Situation kann auch für andere Konzepte auftreten, wenn die Anzahl der insgesamt im Hintergrundwissen betrachteten Konzepte stärker ansteigt und sich Gruppen ähnlicher Konzepte herausbilden.

Problematisch kann dabei auch die Detektion von schlecht beschriebenen Repräsentanten sein, die eigentlich zu einem Konzept einer solchen Gruppe gehören, welches aber nicht im Hintergrundwissen enthalten ist. Hierbei kann sich die Wahrscheinlichkeitsmasse dann auf den Konzepten der Gruppen verteilen, und nicht wie gewünscht über allen Konzepten. Ein Beispiel dafür wird in [Kuw16] gegeben. Dies zeigt auch die Grenzen einer attributbasierten Konzeptbeschreibung in Verbindung mit einer Repräsentant-zu-Konzept Zuordnung als Klassifikationsansatz auf. Ein möglicher Ausweg besteht in der Verwendung eines hierarchischen Klassifikators, der Repräsentanten zunächst nur der Oberklasse eines solchen Konzepts zuordnet, und in dieser in einem weiteren Schritt danach genauer unterscheidet. Dieser Aspekt geht allerdings über den Umfang dieser Arbeit hinaus.

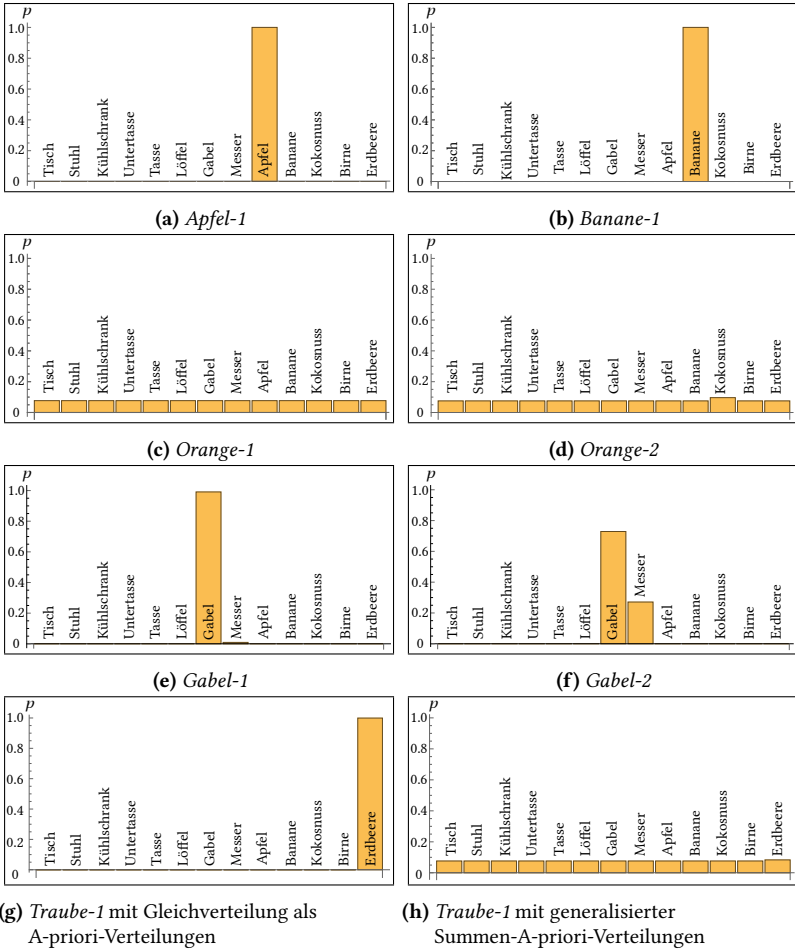


Abbildung 8.11: Beispiele für die Repräsentant-zu-Konzept Zuordnung im komplexeren Evaluationsszenario.

Die letzte Reihe in Abbildung 8.11 illustriert den Effekt der Verwendung unterschiedlicher A-priori-Verteilungen auf die Zuordnungsergebnisse. In Teilabbildung 8.11g wird dabei eine Zuordnungsverteilung für einen schlecht beschriebenen Repräsentanten gezeigt, wenn als A-priori-Verteilungen für alle Attribute Gleichverteilungen über den jeweiligen Wertebereichen angenommen werden. Dagegen zeigt 8.11h die sich ergebende Zuordnung, wenn zumindest für die stetigen Attribute generalisierte Summenverteilungen als A-priori-Verteilungen genutzt werden.

8.6 Zusammenfassung

In diesem Kapitel wurde eine adaptive Modellverwaltung vorgestellt, welche das Analogon der Hintergrundwissens-Komponente zur Informationsverwaltung in der Weltmodell-Komponente darstellt sowie eine Umsetzung der adaptiven Umweltmodellierung beschreibt. Zu diesem Zweck wurden verschiedene Detektionsmaße für schlecht beschriebene Repräsentanten definiert und ein gesamtheitlicher Ablauf für eine adaptive Modellverwaltung in Form einer Regelschleife vorgestellt. Als wichtiger Teilschritt wurde u. a. die Auswahl von relevanten Lernbeispielen für Modellanpassungen präsentiert, basierend auf bereits zuvor definierten Bewertungsmaßen. Weiterhin wurde das Vorgehen für das Erlernen und Generalisieren neuer Konzeptdefinitionen in der adaptiven Umweltmodellierung dargelegt. Schließlich wurde diese adaptive Modellverwaltung und ihre Verfahren anhand eines komplexeren Evaluationsszenarios demonstriert und evaluiert.

9 Zusammenfassung und Ausblick

9.1 Zusammenfassung

In dieser Arbeit wurde ein Ansatz für eine adaptive Umweltmodellierung vorgestellt. Diese stellt eine Erweiterung der objektorientierten Umweltmodellierung dar. Die adaptive Umweltmodellierung betrachtet dabei die Problemstellung, die objektorientierte Umweltmodellierung für offene Welten zu erweitern und diesen einen Umgang mit potentiell unvorhergesehenen Arten von Objekten zu ermöglichen. Die objektorientierte Umweltmodellierung basiert konzeptuell auf der Verwendung eines semantischen Domänenmodells, in welchem für domänenrelevante Entitäten ihre aufgabenbezogene Bedeutung modelliert wird. Derartige Domänenmodelle werden a priori von Wissensingenieuren erstellt. Im Betrieb eines Umweltmodells werden Entitäten in einer relevanten Umgebung beobachtet und mit den semantischen Konzepten des Domänenmodells verknüpft. Die adaptive Umweltmodellierung betrachtet nun den Fall, dass Entitäten in der Umgebung beobachtet werden, für welche im Domänenmodell bisher keine Konzepte modelliert sind.

Diesbezüglich wurde in dieser Arbeit ein Ansatz für eine quantitative Bewertung der Güte eines Domänenmodells entwickelt. Dieser Ansatz bewertet dabei die Fähigkeit eines Modells, die in der Umgebung beobachteten Entitäten erklären und beschreiben zu können. Dazu wurde ein Vorgehen nach dem Prinzip der minimalen Beschreibungslänge für eine Anwendung in der objektorientierten Umweltmodellierung übertragen und detailliert. Das entwickelte Bewertungsmaß berücksichtigt und bewertet dabei in gleichen Teilen die Komplexität eines Domänenmodells als auch dessen Fähigkeit, beobachtete Entitäten erklären zu können.

Die quantitative Modellbewertung dient in dieser Arbeit weiterhin als eine Grundlage zur Steuerung von Modellanpassungen. Zu diesem Zweck wurde zusätzlich ein übergeordneter Ansatz entwickelt, welcher eine adaptive Verwaltung und Anpassung von Domänenmodellen umsetzt. Ein Ziel dieses Ansatzes ist es, Anpassungen an Domänenmodellen nach Prinzipien wie der Bedarfsgerechtigkeit und der Relevanz von Änderungen durchzuführen. Dazu werden im entwickelten Ansatz zunächst die über die Zeit aufgetretenen, schlecht durch ein Domänenmodell beschriebenen Entitäten gespeichert. Mittels eines unüberwachten Selektions- und Gruppierungsansatzes wird daraus eine Menge von Lernbeispielen ausgewählt, die einen für das Umweltmodell relevanten neuen Typ von Entität beschreiben. Auf Basis dieser Lernbeispiele werden schließlich neue probabilistische Konzeptbeschreibung gelernt. Dazu wurde in dieser Arbeit ein Vorgehen entwickelt, welches auch eine Generalisierung gelernter Konzepte erlaubt.

Um durch eine solche induktive Inferenz neue Konzeptbeschreibungen für die objektorientierte Umweltmodellierung erzeugen zu können, wurde in dieser Arbeit weiterhin ein Metamodell und eine Kern-Ontologie für Domänenmodelle entworfen und in der Beschreibungslogik OWL 2 DL umgesetzt. Als Herausforderung mussten dabei im Speziellen die probabilistischen Attribute der Konzepte und die probabilistischen Relationen zwischen Konzepten mittels Beschreibungslogik repräsentiert werden. Weiterhin wurde ein beispielhaftes Modell für die Haushaltsdomäne auf Grundlage der entwickelten Kern-Ontologie realisiert.

Zusätzlich wurden in dieser Arbeit weitere Anpassungen und Erweiterungen der probabilistischen Informationsverarbeitung im objektorientierten Umweltmodell vorgenommen, welche zur Ermöglichung der adaptiven Umweltmodellierung notwendig waren. Dazu zählt die Entwicklung eines alternativen Ansatzes, um beobachtete Entitäten probabilistisch den Konzepten des Domänenmodells zuordnen zu können sowie eine Erweiterung des Ansatzes zur Datenassoziation im objektorientierten Umweltmodell.

9.2 Ausblick

In dieser Arbeit wurde ein erster Ansatz zur Erweiterung der objektorientierten Umweltmodellierung für offene Welten vorgestellt. Dabei wurde ein grundlegendes Vorgehen für eine adaptive Umweltmodellierung entwickelt und demonstriert. Bei der Entwicklung dieses Ansatzes wurden nun auch Aspekte aufgezeigt, welche im Rahmen dieser Arbeit nicht vertieft betrachtet werden konnten und somit mögliche Anteile für zukünftige Arbeiten darstellen. Zum Beispiel wurden in der quantitativen Modellbewertung und Repräsentant-zu-Konzept Zuordnung in dieser Arbeit nur flache Wissensmodelle betrachtet, welche sich durch eine Art Projektion eines hierarchischen Wissensmodells auf dessen Blattknoten ergaben. Ein darüber hinausgehender, interessanter Aspekt für zukünftige Arbeiten wäre die direkte quantitative Gütebewertung eines hierarchischen Wissensmodells, vor allem in Bezug auf eine hierarchische Komplexitätsbewertung. Eng damit verbunden ist auch die Frage, ob bei Vorliegen des Bedarfs für eine Modellanpassung ein gänzlich neues Konzept erstellt oder ein existierendes Konzept erweitert werden soll. Dieser Aspekt wurde in der vorliegenden Arbeit nur oberflächlich betrachtet. Eine hierarchische Modellbewertung könnte dabei genutzt werden, um zu entscheiden, ob entweder ein existierendes Kindkonzept erweitert, ein neues Kindkonzept erstellt oder das entsprechende Vaterkonzept erweitert werden sollte, im Sinne einer minimalen Gesamtbeschreibungslänge für das Wissensmodell und die Repräsentanten. Auch dieser Aspekt stellt eine interessante zukünftige Fragestellung dar.

Gleiches gilt für die Frage, ob und an welcher Stelle ein neu gelerntes Konzept in ein hierarchisches Wissensmodell möglichst automatisiert eingehängt werden kann. Auch dieser Aspekt wurde in der vorliegenden Arbeit nicht vertieft betrachtet und könnte über eine hierarchische Modellbewertung adressiert werden. Ebenfalls könnte der Aspekt über Methoden des Ontologie-Lernens adressiert werden. Eine genauere Untersuchung diesbezüglich stellt somit ebenfalls eine mögliche Erweiterung dieser Arbeit dar. Auch die Integration von Methoden des Ontologie-Lernens zur semantischen Vervollständigung von neu gelernten Konzepten mit zusätzlichen

Attributen stellt eine interessante zukünftige Erweiterung der adaptiven Umweltmodellierung dar.

In dieser Arbeit wurde prinzipiell versucht, die für entwickelte Verfahren notwendigen Parameter wie z. B. Schwellwerte möglichst automatisiert oder, wenn dies nicht möglich war, wenigstens interpretierbar aus modelliertem Vorwissen bzw. über die Zeit erworbenen Umgebungsinformationen abzuleiten. Dies sollte über ein Anwendungsmodell hinaus so weit wie möglich unabhängig von einem konkreten Anwendungsfall erfolgen. Allerdings konnte dieser Aspekt in der vorliegenden Arbeit nicht für die Parameter und Schwellwerte aller Verfahren gleichermaßen umfassend betrachtet werden, so dass sich auch hier zukünftige Arbeiten anschließen können. Dabei kann die grundlegende Frage betrachtet werden, nach welchem Vorgehen Parameter von Verfahren in der objektorientierten und adaptiven Umweltmodellierung auf Basis eines Domänenmodells und beobachteter Informationen automatisiert abgeleitet werden können.

In der objektorientierten und adaptiven Umweltmodellierung wird angenommen, dass Domänenmodelle zunächst von menschlichen Experten erstellt und anschließend bei Bedarf von einem technisch kognitiven System erweitert werden. Eine zusätzliche interessante Fragestellung ergibt sich nun, wenn mehrere kooperierende kognitive System in einem Anwendungsfall zusammenarbeiten. In diesem Fall kann es passieren, dass die einzelnen Systeme jeweils individuelle Modellanpassungen durchführen. Wie solche individuellen Modellanpassungen zu einem konsistenten Gesamtmodell zusammengeführt werden können, stellt somit ebenfalls einen interessanten zukünftigen Forschungsaspekt dar.

Literatur

- [All83] ALLEN, James F.: „Maintaining Knowledge about Temporal Intervals“. In: *Communications of the ACM* 26.11 (1983), S. 832–843 (siehe S. 63).
- [ANS10] ANSI: Guidelines for the Construction, Format, and Management of Monolingual Controlled Vocabularies. Standard ANSI/NISO Z39.19-2005 (R2010). National Information Standards Organization, 2010 (siehe S. 28).
- [Asi18] ASIM, Muhammad Nabeel; WASIM, Muhammad; KHAN, Muhammad Usman Ghani; MAHMOOD, Waqar und ABBASI, Hafiza Mahnoor: „A survey of ontology learning techniques and applications“. In: *Database* 2018 (2018) (siehe S. 70).
- [Baa03] BAADER, Franz und NUTT, Werner: „Basic Description Logics“. In: *The Description Logic Handbook: Theory, Implementation, and Applications*. Hrsg. von BAADER, Franz; MCGUINNESS, Deborah L.; NARDI, Daniele und PATEL-SCHNEIDER, Peter F. Cambridge University Press, 2003. Kap. 2, S. 47–100 (siehe S. 31, 35, 40).
- [Baa05] BAADER, Franz; BRANDT, Sebastian und LUTZ, Carsten: „Pushing the EL envelope“. In: *IJCAI* 5 (Juli 2005), S. 364–369 (siehe S. 33, 35, 36).
- [Bac03] BACH, Joscha: „The MicroPsi Agent Architecture“. In: *Proceedings of the Fifth International Conference on Cognitive Modeling (ICCM-5), 2003*. Bamberg, Apr. 2003, S. 15–20 (siehe S. 71).
- [Bac07] BACH, Joscha: „Principles of Synthetic Intelligence - Building Blocks for an Architecture of Motivated Cognition“. Diss. Osnabrück: Universität Osnabrück, 2007 (siehe S. 71).

- [Bal15] BALA, Kavita: „Recognition: Overview and History“. In: *Introduction to Computer Vision (CS4670/5670), Lecture 26, Cornell University* (2015). zuletzt abgerufen: 2020-06-07. URL: http://www.cs.cornell.edu/courses/cs4670/2015sp/lectures/lec26_reco_web.pdf (siehe S. 80).
- [Bar09] BAR-SHALOM, Yaakov; DAUM, Fred und HUANG, Jim: „The Probabilistic Data Association Filter“. In: *IEEE Control Systems Magazine* 29.6 (2009), S. 82–100 (siehe S. 188).
- [Bat06] BATEMAN, John und FARRAR, Scott: *Spatial Ontology Baseline - Deliverable D2, I1-[OntoSpace]*. Techn. Ber. Bremen: Universität Bremen, 2006 (siehe S. 59, 61, 62).
- [Bau09] BAUER, Alexander; EMTER, Thomas; VAGTS, Hauke und BEYERER, Jürgen: „Object-Oriented World Model for Surveillance Systems“. In: *Future Security: 4th Security Research Conference, 2009*. Karlsruhe, Okt. 2009, S. 339–345 (siehe S. 3, 5, 50, 88, 99–102).
- [Bau10] BAUM, Marcus; GHEȚA, Ioana; BELKIN, Andrey; BEYERER, Jürgen und HANEBECK, Uwe D.: „Data Association in a World Model for Autonomous Systems“. In: *2010 IEEE Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI), 2010*. Salt Lake City, UT, USA, Sep. 2010, S. 187–192 (siehe S. 8, 171, 181, 185, 187, 189–196, 199, 204, 215, 216, 219).
- [Bel09] BELKIN, Andrey: *Object-Oriented World Modelling for Autonomous Systems*. Techn. Ber. IES-2009-16. Lehrstuhl für Interaktive Echtzeitsysteme (IES), Karlsruher Institut für Technologie (KIT), 2009, S. 231–246 (siehe S. 98, 171, 180, 220, 236, 239).
- [Bel12a] BELKIN, Andrey und BEYERER, Jürgen: „Information Entropy and Structural Metrics based Estimation of Situations as a Basis for Situation Awareness and Decision Support“. In: *2012 IEEE International Multi-Disciplinary Conference on Cognitive*

- Methods in Situation Awareness and Decision Support (CogSI-MA)*, 2012. New Orleans, LA, USA, März 2012, S. 111–116 (siehe S. 99, 244, 252, 255, 290).
- [Bel12b] BELKIN, Andrey und BEYERER, Jürgen: „Prior Knowledge Employment Based on the K-L and Tanimoto Distances Matching for Intelligent Autonomous Robots“. In: *Intelligent Robotics and Applications*. Hrsg. von SU, Chun-Yi; RAKHEJA, Subhash und LIU, Honghai. Bd. 7508. Lecture Notes in Computer Science. Springer Berlin Heidelberg, 2012, S. 171–180. URL: http://dx.doi.org/10.1007/978-3-642-33503-7_18 (siehe S. 239, 248, 252, 294).
- [Bel12c] BELKIN, Andrey; KUWERTZ, Achim; FISCHER, Yvonne und BEYERER, Jürgen: „World Modeling for Autonomous Systems“. In: *Innovative Information Systems Modelling Techniques*. Hrsg. von KALLONIATIS, Christos. InTech, Mai 2012, S. 137–158 (siehe S. 8, 87, 88).
- [Bel17] BELKIN, Andrey: „World Modeling for Intelligent Autonomous Systems“. Diss. Karlsruhe: Karlsruher Institut für Technologie (KIT), 2017. URL: <https://dx.doi.org/10.5445/KSP/1000066938> (siehe S. 5, 171, 244, 252–256, 263, 269, 279).
- [Ber01] BERNERS-LEE, Tim; HENDLER, James und LASSILA, Olli: „The Semantic Web“. In: *Scientific American Magazine* 284 (Mai 2001) (siehe S. 33).
- [Ber06] BERNERS-LEE, Tim: Linked Data. in: www.w3.org, zuletzt abgerufen: 2020-06-07. 2006. URL: <https://www.w3.org/DesignIssues/LinkedData> (siehe S. 56).
- [Bey07] BEYERER, Jürgen: „Objektorientierte Fusion - Informationsdrehscheibe und relevantes Abbild der realen Welt“. In: *visIT* 8.3 (2007), S. 4–7 (siehe S. 3, 88, 98, 121).
- [Bor13] BORGES, Helyane Bronoski; SILLA JR., Carlos N. und NIEVOLA, Júlio Cesar: „An evaluation of global-model hierarchical classification algorithms for hierarchical classification problems

- with single path of labels“. In: *Computers & Mathematics with Applications* 66.10 (2013), S. 1991–2002 (siehe S. 249, 250).
- [Bou16] BOUVRY, Pascal; CHAUMETTE, Serge; DANOY, Grégoire; GUERRINI, Gilles; JURQUET, Gilles; KUWERTZ, Achim; MÜLLER, Wil-muth; ROSALIE, Martin und SANDER, Jennifer: „Using Hete-rogeneous Multilevel Swarms of UAVs and High-Level Da-ta Fusion to Support Situation Management in Surveillance Scenarios“. In: *2016 IEEE International Conference on Multisen-sor Fusion and Integration for Intelligent Systems (MFI 2016)*. Baden-Baden, 2016, S. 424–429. URL: <https://doi.org/10.1109/MFI.2016.7849525> (siehe S. 50).
- [Brä03] BRÄUER, Holm: „Ontologie“. In: *Handwörterbuch Philosophie*. Hrsg. von REHFUß, W. D. Göttingen: Vandenhoeck & Ru-precht, 2003, S. 50 (siehe S. 28).
- [Bra17] BRAY, T.: The JavaScript Object Notation (JSON) Data Inter-change Format. RFC 8259. zuletzt abgerufen: 2020-06-07. In-ternet Engineering Task Force IETF, Dez. 2017. URL: <https://tools.ietf.org/html/rfc8259> (siehe S. 242).
- [Bro00] BROCKHAUS: Der Brockhaus von A-Z. F. A. Brockhaus, 2000 (siehe S. 28).
- [Car11] CARVALHO, Rommel Novaes: „Probabilistic Ontology: Repre-sentation and Modeling Methodology“. Diss. Fairfax, VA, USA: George Mason University, 2011 (siehe S. 18, 20, 47, 107).
- [Cha01] CHANDLER, Daniel: *Semiotics: The Basics*. Routledge, 2001 (sie-he S. 26).
- [Che76] CHEN, Peter Pin-Shan: „The Entity-Relationship Model - Toward a Unified View of Data“. In: *ACM Transactions on Database Systems (TODS)* 1.1 (März 1976), S. 9–36 (siehe S. 18).

- [Cim06] CIMIANO, Philipp; HARTUNG, Matthias und RATSCH, Esther: „Finding the Appropriate Generalization Level for Binary Ontological Relations Extracted from the Genia Corpus“. In: *Proceedings of the International Conference on Language Resources and Evaluation (LREC), 2006*. 2006, S. 191–196 (siehe S. 70).
- [Cla01] CLAUS, Volker und SCHWILL, Andreas: Duden Informatik. Dudenverlag, 2001 (siehe S. 26, 27).
- [Cle93] CLEMENTINI, Eliseo; DI FELICE, Paolino und OOSTEROM, Peter van: „A Small Set of Formal Topological Relationships Suitable for End-User Interaction“. In: *Proceedings of the Third International Symposium on Advances in Spatial Databases, 1993*. Berlin, Heidelberg: Springer-Verlag, 1993, S. 277–295 (siehe S. 62).
- [Col09] COLLET, Alvaro; BERENSON, Dmitry; SRINIVASA, Siddhartha S. und FERGUSON, Dave: „Object Recognition and Full Pose Registration from a Single Image for Robotic Manipulation“. In: *IEEE International Conference on Robotics and Automation (ICRA 2009)*. Mai 2009, S. 48–55 (siehe S. 77).
- [Cor03] CORADESCHI, Silvia und SAFFIOTTI, Alessandro: „An Introduction to the Anchoring Problem“. In: *Robotics and Autonomous Systems* 43 (2003), S. 85–96 (siehe S. 51).
- [Cos05] COSTA, Paulo C. G.: „Bayesian Semantics for the Semantic Web“. Diss. Fairfax, VA, USA: George Mason University, 2005. URL: <https://hdl.handle.net/1920/455> (siehe S. 47, 107).
- [Cov91] COVER, Thomas M. und THOMAS, Joy A.: *Elements of Information Theory*. New York, NY, USA: Wiley-Interscience, 1991 (siehe S. 290, 294).
- [Dal05] DALAL, Navneet und TRIGGS, Bill: „Histograms of Oriented Gradients for Human Detection“. In: *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR 2005)*. San Diego, CA, USA, Juni 2005, 886–893, vol. 1. URL: <http://dx.doi.org/10.1109/CVPR.2005.177> (siehe S. 78).

- [Dam03] DAMM, Daniela: „Eine IS-Plattform zur Unterstützung kooperativer interorganisationaler Netzwerke“. Diss. Zürich: Universität Zürich, 2003 (siehe S. 37).
- [Dao12] DAOUTIS, Marios; CORADESCHI, Silvia und LOUTFI, Amy: „Towards concept anchoring for cognitive robots“. In: *Intelligent Service Robotics* 5.4 (2012), S. 213–228 (siehe S. 72–74).
- [Dao13] DAOUTIS, Marios: „Knowledge Based Perceptual Anchoring“. In: *KI - Künstliche Intelligenz* 27.2 (2013), S. 179–182. URL: <http://dx.doi.org/10.1007/s13218-013-0249-0> (siehe S. 72, 109).
- [Das08] DAS, Subrata: *High-Level Data Fusion*. Artech House, Boston, 2008 (siehe S. 88).
- [Dem68] DEMPSTER, Arthur P.: „A generalization of Bayesian inference“. In: *Journal of the Royal Statistical Society: Series B (Methodological)* 30.2 (1968), S. 205–232 (siehe S. 40).
- [Don03] DONINI, Francesco M.: „Complexity of Reasoning“. In: *The Description Logic Handbook: Theory, Implementation, and Applications*. Hrsg. von BAADER, Franz; MCGUINNESS, Deborah L.; NARDI, Daniele und PATEL-SCHNEIDER, Peter F. Cambridge University Press, 2003. Kap. 3, S. 101–141 (siehe S. 32, 33, 36).
- [Dud96] DUDENREDAKTION (o. J.): *Duden, Rechtschreibung der deutschen Sprache*. Dudenverlag, 1996 (siehe S. 26).
- [Emt08] EMTER, Thomas; GHETȂ, Ioana und BEYERER, Jürgen: „Object Oriented Environment Model for Video Surveillance Systems“. In: *Future Security: 3rd Security Research Conference, 2008*. Karlsruhe, 2008, S. 315–320 (siehe S. 3, 88).
- [Far09] FARHADI, Ali; ENDRES, Ian; HOIEM, Derek und FORSYTH, David A.: „Describing Objects by their Attributes“. In: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2009)*. Miami, FL, USA, Juni 2009, S. 1778–1785 (siehe S. 80, 81, 83).

- [Fel00] FELZENSZWALB, Pedro F. und HUTTENLOCHER, Daniel P.: „Efficient Matching of Pictorial Structures“. In: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2000)*. Bd. 2. Hilton Head Island, SC, USA, Juni 2000, 66–73 vol.2. URL: <http://dx.doi.org/10.1109/CVPR.2000.854739> (siehe S. 77).
- [Fel10] FELZENSZWALB, Pedro F.; GIRSHICK, Ross B.; MCALLESTER, David und RAMANAN, Deva: „Object Detection with Discriminatively Trained Part-Based Models“. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence (PAMI)* 32.9 (Sep. 2010), S. 1627–1645. URL: <http://dx.doi.org/10.1109/TPAMI.2009.167> (siehe S. 77).
- [Fet16] FETTKE, Peter: „UML-basierte Modellierung“. In: *Enzyklopädie der Wirtschaftsinformatik*. Bd. 11. Auflage. (Abruf: 07.06.2020). Berlin: GITO, 2016. URL: <http://www.enzyklopaedie-der-wirtschaftsinformatik.de> (siehe S. 19).
- [Fis10] FISCHER, Yvonne und BAUER, Alexander: „Object-Oriented Sensor Data Fusion for Wide Maritime Surveillance“. In: *2010 International Waterside Security Conference (WSS 2010)*. Carrara, Italien, Nov. 2010, S. 1–6. URL: <https://dx.doi.org/10.1109/WSSC.2010.5730244> (siehe S. 50).
- [Fis11] FISCHER, Yvonne; BAUER, Alexander und BEYERER, Jürgen: „A Conceptual Framework for Automatic Situation Assessment“. In: *2011 IEEE First International Multi-Disciplinary Conference on Cognitive Methods in Situation Awareness and Decision Support (CogSIMA), 2011*. Miami Beach, FL, USA, Feb. 2011, S. 234–239. DOI: 10.1109/COGSIMA.2011.5753451 (siehe S. 223, 224).
- [Fis12] FISCHER, Yvonne und BEYERER, Jürgen: „A Top-Down-View on Intelligent Surveillance Systems“. In: *Proceedings of the Seventh International Conference on Systems (ICONS 2012)*. Saint Gilles, Réunion, Feb. 2012, S. 43–48 (siehe S. 223, 224).
- [Fis16] FISCHER, Yvonne: „Wissensbasierte probabilistische Modellierung für die Situationsanalyse am Beispiel der maritimen

Überwachung“. Diss. Karlsruhe: Karlsruher Institut für Technologie (KIT), 2016. URL: <https://dx.doi.org/10.5445/KSP/1000051065> (siehe S. 5, 50, 223, 228).

- [Fis73] FISCHLER, Martin A. und ELSCHLAGER, Robert A.: „The Representation and Matching of Pictorial Structures“. In: *IEEE Transactions on Computers* C-22.1 (Jan. 1973), S. 67–92. URL: <http://dx.doi.org/10.1109/T-C.1973.223602> (siehe S. 77).
- [Fis87] FISHER, Douglas H.: „Knowledge Acquisition Via Incremental Conceptual Clustering“. In: *Machine Learning 2.2* (Sep. 1987), S. 139–172 (siehe S. 69).
- [Gal05] GALINDO, Cipriano; SAFFIOTTI, Alessandro; CORADESCHI, Silvia; BUSCHKA, Pär; FERNANDEZ-MADRIGAL, Juan-Antonio und GONZALEZ, Javier: „Multi-Hierarchical Semantic Maps for Mobile Robotics“. In: *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2005)*. Aug. 2005, S. 2278–2283. URL: <http://dx.doi.org/10.1109/IROS.2005.1545511> (siehe S. 51).
- [Gen89] GENNARI, John H.; LANGLEY, Pat und FISHER, Doug: „Models of Incremental Concept Formation“. In: *Artificial intelligence* 40.1-3 (1989), S. 11–61 (siehe S. 69).
- [Ghe08] GHEȚA, Ioana; HEIZMANN, Michael und BEYERER, Jürgen: „Object Oriented Environment Model for Autonomous Systems“. In: *Proceedings of the second Skövde Workshop on Information Fusion Topics (SWIFT 2008)*. Hrsg. von BOSTRÖM, Henrik; JOHANSSON, Ronnie und LAERE, Joeri van. Skövde, Schweden: Skövde Studies in Informatics, 2008, S. 9–12 (siehe S. 88, 101, 171, 181, 213, 222, 223, 234).
- [Ghe10a] GHEȚA, Ioana; BAUM, Marcus; BELKIN, Andrey; BEYERER, Jürgen und HANEBECK, Uwe D.: „Three Pillar Information Management System for Modeling the Environment of Autonomous Systems“. In: *Proceedings of 2010 IEEE Conference on Virtual Environments, Human-Computer Interfaces and Measurement Systems (VECIMS), 2010*. Taranto, Italy, Sep. 2010,

- S. 12–17 (siehe S. 121, 171, 177, 179–182, 185, 187, 215, 216, 220, 234, 236, 239).
- [Ghe10b] GHETA, Ioana; HEIZMANN, Michael; BELKIN, Andrey und BEYERER, Jürgen: „World Modeling for Autonomous Systems“. In: *KI 2010: Advances in Artificial Intelligence, 2010*. Hrsg. von DILLMANN, Rüdiger; BEYERER, Jürgen; HANEBECK, Uwe D. und SCHULTZ, Tanja. Bd. 6359. Lecture Notes in Artificial Intelligence. Karlsruhe: Springer, Sep. 2010, S. 176–183 (siehe S. 3, 88, 98, 99, 101, 121, 171, 219, 222, 223, 239).
- [Gir14] GIRSHICK, Ross; DONAHUE, Jeff; DARRELL, Trevor und MALIK, Jagannath: „Rich feature hierarchies for accurate object detection and semantic segmentation“. In: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2014)*. Columbus, OH, USA, 2014, S. 580–587 (siehe S. 79).
- [Gir15] GIRSHICK, Ross: „Fast R-CNN“. In: *IEEE International Conference on Computer Vision (ICCV 2015)*. Santiago, Chile, Dez. 2015, S. 1440–1448. URL: <http://dx.doi.org/10.1109/ICCV.2015.169> (siehe S. 79).
- [Gli10] GLIMM, Birte; HORROCKS, Ian; MOTIK, Boris und STOILOS, Giorgos: „Optimising Ontology Classification“. In: *International Semantic Web Conference (ISWC 2010)*. Springer, Nov. 2010, S. 225–240 (siehe S. 36).
- [Goo00] Goos, Gerhard: Vorlesungen über Information, Band 1. Springer, 2000 (siehe S. xii, 20–22, 24).
- [Gor06] GORDON, Iryna und LOWE, David G.: „What and Where: 3D Object Recognition with Accurate Pose“. In: *Toward Category-Level Object Recognition*. Springer Berlin Heidelberg, 2006, S. 67–82 (siehe S. 77).
- [Grü07] GRÜNWARD, Peter D.: The Minimum Description Length Principle. The MIT Press, Juni 2007 (siehe S. 67, 282–285).

- [Gru93] GRUBER, Thomas R.: „A Translation Approach to Portable Ontology Specifications“. In: *Knowledge Acquisition* 5.2 (1993), S. 199–220. DOI: <http://dx.doi.org/10.1006/knac.1993.1008> (siehe S. 28).
- [Gru95] GRUBER, Thomas R.: „Toward Principles for the Design of Ontologies Used for Knowledge Sharing“. In: *International Journal Human-Computer Studies* 43.5-6 (1995), S. 907–928 (siehe S. 38).
- [Grü95] GRÜNINGER, Michael und FOX, Mark S.: „Methodology for the Design and Evaluation of Ontologies“. In: *Workshop on Basic Ontological Issues in Knowledge Sharing, IJCAI-95 (1995)*. Montreal, Kanada, 1995 (siehe S. 37).
- [Gua02] GUARINO, Nicola und WELTY, Christopher: „Evaluating Ontological Decisions with OntoClean“. In: *Communications of the ACM* 45.2 (2002), S. 61–65 (siehe S. 38, 132, 156).
- [Gua04] GUARINO, Nicola und WELTY, Christopher: „An Overview of OntoClean“. In: *Handbook on Ontologies*. Springer, 2004, S. 151–171 (siehe S. 109, 156).
- [Gua98] GUARINO, Nicola: „Formal Ontology and Information Systems“. In: *Formal Ontology in Information Systems: Proceedings of the First International Conference (FOIS 1998)*. Trento, Italien, 1998, S. 3–15 (siehe S. 29, 30).
- [He16] HE, Kaiming; ZHANG, Xiangyu; REN, Shaoqing und SUN, Jian: „Deep Residual Learning for Image Recognition“. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2016), 2016*. 2016, S. 770–778 (siehe S. 79, 83).
- [Hei10] HEIZMANN, Michael; GHETA, Ioana; PUENTE LEÓN, Fernando und BEYERER, Jürgen: „Sensoreinsatzplanung und Informationsfusion zur Umgebungsexploration“. In: *tm - Technisches Messen* 77.10 (Okt. 2010), S. 558–567 (siehe S. 3, 40, 88, 98, 99, 113, 121, 171, 179, 180, 204, 218–220).

- [Hen12] HENDERSON, Annette M.E.; SABBAGH, Mark A. und WOODWARD, Amanda L.: „Preschoolers’ selective learning is guided by the principle of relevance“. In: *Cognition* 126.2 (2012), S. 246–257 (siehe S. 92).
- [Hor03] HORROCKS, Ian; MCGUINNESS, Deborah L. und WELTY, Christopher A.: „Digital Libraries and Web-Based Information Systems“. In: *The Description Logic Handbook: Theory, Implementation, and Applications*. Hrsg. von BAADER, Franz; MCGUINNESS, Deborah L.; NARDI, Daniele und PATEL-SCHNEIDER, Peter F. Cambridge University Press, 2003. Kap. 14, S. 436–459 (siehe S. 34).
- [Hor09] HORRIDGE, Paul und MASKELL, Simon: „Searching for, initiating and tracking multiple targets using existence probabilities“. In: *Proceedings of the 12th International Conference on Information Fusion (Fusion 2009)*. Seattle, WA, USA, Juli 2009, S. 611–617 (siehe S. 194–197, 199, 204, 206, 215–218).
- [How09] HOWARD, Catherine und STUMPTNER, Markus: „Automated compilation of Object-Oriented Probabilistic Relational Models“. In: *International Journal of Approximate Reasoning* 50.9 (Mai 2009), S. 1369–1398. URL: <http://dx.doi.org/10.1016/j.ijar.2009.04.011> (siehe S. 17, 25, 44, 46, 50, 107, 108, 124).
- [How10] HOWARD, Catherine: „Knowledge Representation and Reasoning for a Model-Based Approach to Higher Level Information Fusion“. Diss. Adelaide, Australien: University of South Australia, 2010 (siehe S. 50).
- [Hub08] HUBER, Marco F. und HANEBECK, Uwe D.: „Progressive Gaussian Mixture Reduction“. In: *Proceedings of the 11th International Conference on Information Fusion (Fusion 2008)*. Köln, Juli 2008, S. 1–8 (siehe S. 345, 346).
- [Isr83] ISRAEL, David J.; BERANEK, Bolt und NEWMAN, Inc.: „The Role of Logic in Knowledge Representation“. In: *Computer* 16.10 (Okt. 1983), S. 37–41. DOI: 10.1109/MC.1983.1654195 (siehe S. 23, 24).

- [Jai11] JAIN, Dominik; GLEISSENTHALL, Klaus von und BEETZ, Michael: „Bayesian Logic Networks and the Search for Samples with Backward Simulation and Abstract Constraint Learning“. In: *KI 2011: Advances in Artificial Intelligence (2011)*. 2011, S. 144–156 (siehe S. 53).
- [Jay68] JAYNES, Edwin T.: „Prior Probabilities“. In: *IEEE Transactions on Systems Science and Cybernetics* 4.3 (1968), S. 227–241 (siehe S. 150).
- [Jor04] JORDAN, Michael I.: „Graphical Models“. In: *Statistical Science* 19.1 (Feb. 2004), S. 140–155. DOI: 10.1214/088342304000000026 (siehe S. 43, 44).
- [Kei19] KEIL, Jan Martin und SCHINDLER, Sirko: „Comparison and Evaluation of Ontologies for Units of Measurement“. In: *Semantic Web* 10.1 (2019), S. 33–51 (siehe S. 63).
- [Kif89] KIFER, Michael und LAUSEN, Georg: „F-Logic: A Higher-Order Language for Reasoning about Objects, Inheritance, and Scheme“. In: *Proceedings of the 1989 ACM SIGMOD International Conference on Management of Data*. Portland, Oregon, USA, 1989, S. 134–146. DOI: 10.1145/67544.66939 (siehe S. 25).
- [Kol97] KOLLER, Daphne und PFEFFER, Avi: „Object-Oriented Bayesian Networks“. In: *Proceedings of the Thirteenth Annual Conference on Uncertainty in Artificial Intelligence (UAI 1997)*. Providence, RI, USA, 1997, S. 302–313 (siehe S. 44, 45).
- [Kol98] KOLLER, Daphne und PFEFFER, Avi: „Probabilistic frame-based systems“. In: *Proceedings of the fifteenth national/tenth conference on Artificial intelligence/Innovative applications of artificial intelligence (AAAI/IAAI 1998)*. Juli 1998, S. 580–587 (siehe S. 17, 25, 44, 46, 107, 124).
- [Kon08] KONISHI, Sadanori und KITAGAWA, Genshiro: *Information Criteria and Statistical Modeling*. Springer Series in Statistics. Springer, 2008 (siehe S. 92).

- [Kuc04] KUCK, G.: „Tim Berners-Lee’s Semantic Web“. In: *South African Journal of Information Management* 6 (Dez. 2004). DOI: 10.4102/sajim.v6i1.297 (siehe S. 33).
- [Küh10] KÜHN, Benjamin; BELKIN, Andrey; SWERDLOW, Alexej; MACHMER, Timo; BEYERER, Jürgen und KROSCHER, Kristian: „Knowledge-Driven Opto-Acoustic Scene Analysis based on an Object- Oriented World Modeling approach for Humanoid Robots“. In: *2010 41st International Symposium on Robotics (ISR) and 2010 6th German Conference on Robotics (ROBOTIK)*. München, Juni 2010, S. 1–8 (siehe S. 98, 101).
- [Kuh55] KUHN, Harold W.: „The Hungarian Method for the Assignment Problem“. In: *Naval Research Logistics Quarterly* 2.1-2 (1955), S. 83–97 (siehe S. 188).
- [Kun10] KUNZE, Lars; TENORTH, Moritz und BEETZ, Michael: „Putting People’s Common Sense into Knowledge Bases of Household Robots“. In: *KI 2010: Advances in Artificial Intelligence (2010)*. 2010, S. 151–159 (siehe S. 53).
- [Kuw10] KUWERTZ, Achim: On Adaptive Open-World Modeling Based on Information Fusion and Inductive Inference. Techn. Ber. Karlsruhe: Lehrstuhl für Interaktive Echtzeitsysteme (IES), Karlsruher Institut für Technologie (KIT), 2010 (siehe S. 66, 87).
- [Kuw11] KUWERTZ, Achim: Towards Adaptive Open-World Modeling. Techn. Ber. Karlsruhe: Lehrstuhl für Interaktive Echtzeitsysteme (IES), Karlsruher Institut für Technologie (KIT), 2011 (siehe S. 26).
- [Kuw12a] KUWERTZ, Achim: Extending Object-Oriented World Modeling for Adaptive Open-World Modeling. Techn. Ber. IES-2012-06. Karlsruhe: Lehrstuhl für Interaktive Echtzeitsysteme (IES), Karlsruher Institut für Technologie (KIT), 2012 (siehe S. 8, 68).

- [Kuw12b] KUWERTZ, Achim; FISCHER, Yvonne; ESSENDORFER, Barbara und PEINSIPP-BYMA, Elisabeth: „Using Context Knowledge for Maritime Situation Assessment“. In: *Proceedings of 3rd International WaterSide Security Conference (WSS 2012)*. Singapur, Mai 2012 (siehe S. 50).
- [Kuw13a] KUWERTZ, Achim und BEYERER, Jürgen: „Knowledge Model Quantitative Evaluation for Adaptive World Modeling“. In: *2013 IEEE International Multi-Disciplinary Conference on Cognitive Methods in Situation Awareness and Decision Support (CogSIMA), 2013*. San Diego, CA, USA, Feb. 2013, S. 91–97 (siehe S. 8, 281, 299).
- [Kuw13b] KUWERTZ, Achim und BEYERER, Jürgen: „Quantitative Measures for Adaptive Object-Oriented World Modeling“. In: *Informatik Berichte 368 - 9/2013 – Proceedings of the 4th Workshop on Dynamics of Knowledge and Belief (DKB-2013) at the 36th German Annual Conference on Artificial Intelligence, KI-2013, 2013*. Koblenz, Sep. 2013, S. 89–104 (siehe S. 8, 256, 257, 266, 279, 312).
- [Kuw13c] KUWERTZ, Achim und SCHNEIDER, Gerd: „Ontology-Based Meta Model in Object-Oriented World Modeling for Interoperable Information Access“. In: *Proceedings of the Eighth International Conference on Systems (ICONS 2013)*. Sevilla, Spanien, Jan. 2013, S. 185–191 (siehe S. 8, 112, 113, 119, 120, 139).
- [Kuw14] KUWERTZ, Achim und BEYERER, Jürgen: „Dealing with Poorly Mapped Entities in Adaptive Object-Oriented World Modeling“. In: *2014 IEEE International Inter-Disciplinary Conference on Cognitive Methods in Situation Awareness and Decision Support (CogSIMA), 2014*. San Antonio, TX, USA, März 2014, S. 83–89 (siehe S. 8, 327, 338, 348, 349).
- [Kuw15] KUWERTZ, Achim; GOLDBECK, Cornelius; HUG, Ronny und BEYERER, Jürgen: „Towards Web-based Semantic Knowledge Completion for Adaptive World Modeling in Cognitive Systems“. In: *Proceedings of the UKSIM-AMSS 17th International*

- Conference on Modelling and Simulation (UKSim2015)*, 2015. Cambridge, UK, März 2015, S. 165–170 (siehe S. 335–337).
- [Kuw16] KUWERTZ, Achim und BEYERER, Jürgen: „Extending Adaptive World Modeling by Identifying and Handling Insufficient Knowledge Models“. In: *Journal of Applied Logic* 19 (2016). SI: Dynamics of Knowledge and Belief, S. 102–127. doi: <https://doi.org/10.1016/j.jal.2016.05.005> (siehe S. 8, 91, 141, 142, 256, 257, 271, 276, 279, 320, 350, 362).
- [Kuw17] KUWERTZ, Achim; SANDER, Jennifer; PFIRRMANN, Uwe und DYCK, Sergius: „High-Level Information Management in Joint ISR based on an Object-Oriented Approach“. In: *2017 Sensor Data Fusion: Trends, Solutions, Applications (SDF 2017)*. Bonn, 2017, S. 1–6. URL: <https://doi.org/10.1109/SDF.2017.8126360> (siehe S. 50).
- [Kuw18] KUWERTZ, Achim; MÜHLENBERG, Dirk; SANDER, Jennifer und MÜLLER, Wilmoth: „Applying Knowledge-Based Reasoning for Information Fusion in Intelligence, Surveillance, and Reconnaissance“. In: *Multisensor Fusion and Integration in the Wake of Big Data, Deep Learning and Cyber Physical System (2018)*. Cham: Springer International Publishing, 2018, S. 119–139. URL: https://doi.org/10.1007/978-3-319-90509-9_7 (siehe S. 50).
- [Lam09] LAMPERT, Christoph H.; NICKISCH, Hannes und HARMLING, Stefan: „Learning To Detect Unseen Object Classes by Between-Class Attribute Transfer“. In: *IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2009)*. Miami, FL, USA, Juni 2009, S. 951–958 (siehe S. 80, 81, 83).
- [Las08] LASKEY, Kathryn Blackmond: „MEBN: A language for first-order Bayesian knowledge bases“. In: *Artificial Intelligence* 172.2 (2008), S. 140–178. doi: <https://doi.org/10.1016/j.artint.2007.09.006> (siehe S. 17, 20, 47).

- [Las11] LASKEY, Kathryn B.; HABERLIN, Richard; CARVALHO, Rommel N. und COSTA, Paulo C. G. da: „PR-OWL 2 Case Study: A Maritime Domain Probabilistic Ontology.“ In: *Proceedings of the Sixth International Conference on Semantic Technologies for Intelligence, Defense, and Security (STIDS 2011)*. 2011, S. 76–83 (siehe S. 50, 107, 108).
- [LeC15] LECUN, Yann; BENGIO, Yoshua und HINTON, Geoffrey: „Deep Learning“. In: *Nature* 521.7553 (2015), S. 436–444 (siehe S. 79).
- [LeC98] LECUN, Yann; BOTTOU, Léon; BENGIO, Yoshua und HAFNER, Patrick: „Gradient-Based Learning Applied to Document Recognition“. In: *Proceedings of the IEEE* 86.11 (Nov. 1998), S. 2278–2324. URL: <http://dx.doi.org/10.1109/5.726791> (siehe S. 78).
- [Leh15] LEHMANN, Jens; ISELE, Robert; JAKOB, Max; JENTZSCH, Anja; KONTOKOSTAS, Dimitris; MENDES, Pablo N; HELLMANN, Sebastian; MORSEY, Mohamed; KLEEF, Patrick van; AUER, Sören u. a.: „DBpedia - A Large-scale, Multilingual Knowledge Base Extracted from Wikipedia“. In: *Semantic Web* 6.2 (2015), S. 167–195 (siehe S. 55, 56, 109).
- [Lem11] LEMAIGNAN, Séverin; ROS, Raquel; SISBOT, E. Akin; ALAMI, Rachid und BEETZ, Michael: „Grounding the Interaction: Anchoring Situated Discourse in Everyday Human-Robot Interaction“. In: *International Journal of Social Robots* (2011), S. 1–19. URL: <http://dx.doi.org/10.1007/s12369-011-0123-x> (siehe S. 53, 54, 108).
- [Lem12] LEMAIGNAN, Séverin: „Grounding the Interaction: Knowledge Management for Interactive Robots“. Diss. München: Technische Universität München, 2012 (siehe S. 54).
- [Len95] LENAT, Douglas B.: „CYC: A Large-Scale Investment in Knowledge Infrastructure“. In: *Commun. ACM* 38.11 (Nov. 1995), S. 33–38. DOI: 10.1145/219717.219745 (siehe S. 52, 55, 57, 108).

- [Lim11] LIM, G. H.; SUH, I. H. und SUH, H.: „Ontology-Based Unified Robot Knowledge for Service Robots in Indoor Environments“. In: *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans* 41.3 (Mai 2011), S. 492–509. DOI: 10.1109/TSMCA.2010.2076404 (siehe S. 53, 77, 108).
- [Lin12] LINEHAN, Mark H.; BARKMEYER, Ed und HENDRYX, Stan: „The Date-Time Vocabulary“. In: *Seventh International Conference on Formal Ontologies in Information Systems (FOIS 2012)*. 2012, S. 265–378 (siehe S. 62).
- [Liu04] LIU, Hugo und SINGH, Push: „ConceptNet - a Practical Commonsense Reasoning Tool-Kit“. In: *BT Technology Journal* 22.4 (2004), S. 211–226 (siehe S. 55, 56, 109).
- [Low04] LOWE, David G.: „Distinctive Image Features from Scale-Invariant Keypoints“. In: *International Journal of Computer Vision* 60.2 (Nov. 2004), S. 91–110. URL: <http://dx.doi.org/10.1023/B:VISI.0000029664.99615.94> (siehe S. 78).
- [Low99] LOWE, David G.: „Object Recognition from Local Scale-Invariant Features“. In: *The Proceedings of the Seventh IEEE International Conference on Computer Vision (ICCV 1999)*. Bd. 2. Kerkyra, Korfu, Griechenland, Sep. 1999, S. 1150–1157. URL: <http://dx.doi.org/10.1109/ICCV.1999.790410> (siehe S. 78).
- [Mas03] MASOLO, Claudio; BORGIO, Stefano; GANGEMI, Aldo; GUARINO, Nicola; OLTRAMARI, Alessandro und SCHNEIDER, Luc: *Wonder-Web Deliverable D18 - Ontology Library (final)*. Techn. Ber. Trento, Italien: Laboratory For Applied Ontology, 2003 (siehe S. 30, 58, 109, 130–132, 138).
- [Mat06] MATUSZEK, Cynthia; WITBROCK, Michael; CABRAL, John und DEOLIVEIRA, John: „An Introduction to the Syntax and Content of Cyc“. In: *UMBC Computer Science and Electrical Engineering Department Collection* (2006) (siehe S. 58).
- [Mil06] MILCH, Brian und RUSSELL, Stuart: „First-Order Probabilistic Languages: Into the Unknown“. In: *Inductive Logic Programming*. Springer, 2006, S. 10–24 (siehe S. 44, 45).

- [Mil95] MILLER, George A.: „WordNet: a lexical database for English“. In: *Communications of the ACM* 38.11 (1995), S. 39–41 (siehe S. 55, 109).
- [Min74] MINSKY, Marvin: *A Framework for Representing Knowledge*. Techn. Ber. USA: Massachusetts Institute of Technology, 1974 (siehe S. 24).
- [Mit79] MITCHELL, Tom M.: „Version Spaces: An Approach to Concept Learning“. Diss. Stanford, CA, USA: Stanford University, 1979 (siehe S. 67, 341).
- [Mit80] MITCHELL, Tom M.: *The Need for Biases in Learning Generalizations*. Techn. Ber. CBM-TR-117. Rutgers Computer Science Department, 1980 (siehe S. 68).
- [Mit97] MITCHELL, Tom M.: *Machine Learning*. 1st. McGraw-Hill Education (ISE Editions), Okt. 1997 (siehe S. 66).
- [Mor70] MORRIS, Charles W.: *Foundations of the Theory of Signs*. Chicago, IL, USA: Chicago University Press, 1938/1970 (siehe S. 27).
- [Mur95] MURASE, Hiroshi und NAYAR, Shree K.: „Visual Learning and Recognition of 3-D Objects from Appearance“. In: *International Journal of Computer Vision* 14.1 (Jan. 1995), S. 5–24. URL: <http://dx.doi.org/10.1007/BF01421486> (siehe S. 77).
- [Mus15] MUSEN, Mark A.: „The Protégé Project: A Look Back and a Look Forward“. In: *AI Matters* 1.4 (Juni 2015), S. 4–12. DOI: 10.1145/2757001.2757003 (siehe S. 36).
- [Nie14] NIENHÜSER, Dennis: „Kontextsensitive Erkennung und Interpretation fahrrelevanter statischer Verkehrselemente“. Diss. Karlsruhe: Karlsruher Institut für Technologie (KIT), 2014. URL: <http://dx.doi.org/10.5445/IR/1000037913> (siehe S. 50).

- [Nil01] NILES, Ian und PEASE, Adam: „Towards a Standard Upper Ontology“. In: *Proceedings of the International Conference on Formal Ontology in Information Systems (FOIS 2001)*. Association for Computing Machinery, 2001, S. 2–9. doi: 10.1145/505168.505170 (siehe S. 58, 109).
- [NIM00] NIMA: WORLD GEODETIC SYSTEM 1984. Techn. Ber. TR 8350.2 Third Edition. St. Louis, MO, USA: National Imagery und Mapping Agency, 2000 (siehe S. 60).
- [Noa10] NOACK, Benjamin; KLUMPP, Vesa; LYONS, Daniel und HANEBECK, Uwe D.: „Modellierung von Unsicherheiten und Zustandsschätzung mit Mengen von Wahrscheinlichkeitsdichten“. In: *tm-Technisches Messen Plattform für Methoden, Systeme und Anwendungen der Messtechnik* 77.10 (2010), S. 544–550 (siehe S. 40).
- [Noy01] NOY, Natalya F. und MCGUINNESS, Deborah L.: *Ontology Development 101: A Guide to Creating Your First Ontology*. Techn. Ber. Stanford, CA, USA: Stanford University, 2001 (siehe S. 37).
- [Osw91] OSWALD, Jacques R.: *Diacritical Analysis of Systems: a Treatise on Information Theory*. Ellis Horwood series in electrical and electronic engineering. E. Horwood, 1991 (siehe S. 290).
- [Par11] PARIKH, Devi und GRAUMAN, Kristen: „Relative Attributes“. In: *IEEE International Conference on Computer Vision (ICCV 2011)*. Barcelona, Spanien, Nov. 2011, S. 503–510 (siehe S. 80, 83).
- [Pei58] PEIRCE, Charles Sanders: *Collected Writings*. Cambridge, MA, USA: Harvard University Press, 1931-58 (siehe S. 26).
- [Pfe99] PFEFFER, Avi; KOLLER, Daphne; MILCH, Brian und TAKUSAGAWA, Ken T.: „SPOOK: A system for probabilistic object-oriented knowledge representation“. In: *UAI '99: Proceedings of the Fifteenth Conference on Uncertainty in Artificial Intelligence (1999)*. Stockholm, Schweden, 1999, S. 541–550. URL: <https://dslpitt.org/uai/papers/99/p541-pfeffer.pdf> (siehe S. 50).

- [Pul88] PULLAR, David und EGENHOFER, Max J.: „Towards Formal Definitions of Topological Relations Among Spatial Objects“. In: *Proceedings of the 3rd International Symposium on Spatial Data Handling, 1988*. Sydney, Australien, 1988, S. 225–242 (siehe S. 61).
- [Ran92] RANDELL, David A.; CUI, Zhan und COHN, Anthony G.: „A Spatial Logic Based on Regions and Connection“. In: *Proceedings of the Third International Conference on Principles of Knowledge Representation and Reasoning, 1992*. Cambridge, MA, USA, 1992, S. 165–176 (siehe S. 61).
- [Reb16] REBELE, Thomas; SUCHANEK, Fabian; HOFFART, Johannes; BIEGA, Joanna; KUZEY, Erdal und WEIKUM, Gerhard: „YAGO: A multilingual knowledge base from Wikipedia, Wordnet, and Geonames“. In: *International Semantic Web Conference (2016)*. 2016, S. 177–185 (siehe S. 55, 57, 109).
- [Red17] REDMON, Joseph und FARHADI, Ali: „YOLO9000: Better, Faster, Stronger“. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2017)*. 2017, S. 7263–7271 (siehe S. 79).
- [Ren15] REN, Shaoqing; HE, Kaiming; GIRSHICK, Ross und SUN, Jian: „Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks“. In: *Advances in Neural Information Processing Systems 28 (NIPS 2015)*. Montréal, Canada, 2015, S. 91–99 (siehe S. 79).
- [Rij13] RIJGERSBERG, Hajo; ASSEM, Mark van und TOP, Jan: „Ontology of Units of Measure and Related Concepts“. In: *Semantic Web 4.1* (Jan. 2013), S. 3–13 (siehe S. 63, 136).
- [Ris78] RISSANEN, Jorma: „Modeling by Shortest Data Description“. In: *Automatica* 14.5 (Sep. 1978), S. 465–471 (siehe S. 282).
- [Rob15] ROBINSON, Stewart; ARBEZ, Gilbert; BIRTA, Louis G.; TOLK, Andreas und WAGNER, Gerd: „Conceptual Modeling: Definition, Purpose and Benefits“. In: *2015 Winter Simulation Conference*

- (WSC 2015). Dez. 2015, S. 2812–2826. doi: 10.1109/WSC.2015.7408386 (siehe S. 18).
- [Rum04] RUMBAUGH, James; JACOBSON, Ivar und BOOCH, Grady: the Unified Modeling Language Reference Manual. Pearson Higher Education, 2004 (siehe S. 19).
- [Run07] RUNNALLS, Andrew R.: „A Kullback-Leibler Approach to Gaussian Mixture Reduction“. In: *IEEE Trans. Aerosp. Electron. Syst* (2007), S. 989–999 (siehe S. 345, 346).
- [Rus10] RUSSELL, Stuart J. und NORVIG, Peter: *Artificial Intelligence: A Modern Approach*. 3. Aufl. Prentice Hall, 2010 (siehe S. 24, 25, 31, 39–44, 58, 188, 248).
- [Sal09] SALMOND, David J.: „Mixture Reduction Algorithms for Point and Extended Object Tracking in Clutter“. In: *IEEE Transactions on Aerospace and Electronic Systems* 45.2 (2009), S. 667–686 (siehe S. 345, 346).
- [Sch06] SCHÖNBEIN, Rainer: „Agenten- und ontologiebasierte Software-Architektur zur interaktiven Bildauswertung“. Diss. Karlsruhe: Universität Karlsruhe (TH), 2006 (siehe S. 29, 30, 109).
- [Sch11] SCHREMPF, Detlef und HANEBECK, Uwe D.: *Textbook for Lecture on Stochastic Information Processing*. Intelligent Sensor-Actuator-Systems Laboratory (ISAS), Karlsruhe Institute of Technology (KIT), Nov. 2011 (siehe S. 39, 42, 258–260).
- [Sch14] SCHAMM, Thomas: „Modellbasierter Ansatz zur probabilistischen Interpretation von Fahrsituationen“. Diss. Karlsruhe: Karlsruher Institut für Technologie (KIT), 2014 (siehe S. 50, 108).
- [Sha76] SHAFER, Glenn: *A Mathematical Theory of Evidence*. Princeton University Press, 1976 (siehe S. 40).

- [Sil11] SILLA JR., Carlos N. und FREITAS, Alex A.: „A survey of hierarchical classification across different application domains“. In: *Data Mining and Knowledge Discovery* 22.1-2 (2011), S. 31–72 (siehe S. 249, 253).
- [Sir07] SIRIN, Evren; PARSIA, Bijan; GRAU, Bernardo Cuenca; KALYANPUR, Aditya und KATZ, Yarden: „Pellet: A practical OWL-DL reasoner“. In: *Journal of Web Semantics* 5.2 (2007), S. 51–53. URL: <https://doi.org/10.1016/j.websem.2007.03.004> (siehe S. 36).
- [Sok66] SOKAL, Robert R.: „Numerical Taxonomy“. In: *Scientific American* 215.6 (1966), S. 106–116 (siehe S. 68).
- [Sow99] SOWA, John F.: *Knowledge Representation: Logical, Philosophical and Computational Foundations*. Pacific Grove, CA, USA: Brooks/Cole Publishing Co., 1999 (siehe S. 58).
- [Sto02] STOLLBERG, Michael: „Ontologiebasierte Wissensmodellierung“. Magisterarbeit. Berlin: Freie Universität Berlin, 2002 (siehe S. 37).
- [Str13a] STRAHRINGER, Susanne: „Konzeptuelle Modellierung von Informationssystemen“. In: *Enzyklopädie der Wirtschaftsinformatik*. Bd. 11. Auflage. (Abruf: 07.06.2020). Berlin: GITO, 2013. URL: <http://www.encyklopaedie-der-wirtschaftsinformatik.de> (siehe S. 18, 19).
- [Str13b] STRAHRINGER, Susanne: „Metamodell“. In: *Enzyklopädie der Wirtschaftsinformatik*. Bd. 11. Auflage. (Abruf: 15.06.2020). Berlin: GITO, 2013. URL: <http://www.encyklopaedie-der-wirtschaftsinformatik.de> (siehe S. 111).
- [Stu19a] STUCKENSCHMIDT, Heiner: „Semantic Web“. In: *Enzyklopädie der Wirtschaftsinformatik*. Bd. 11. Auflage. (Abruf: 09.06.2020). Berlin: GITO, 2019. URL: <http://www.encyklopaedie-der-wirtschaftsinformatik.de> (siehe S. 34).

- [Stu19b] STUDER, Rudi und SURE-VETTER, York: „Ontologien“. In: *Enzyklopädie der Wirtschaftsinformatik*. Bd. 11. Auflage. (Abruf: 09.06.2020). Berlin: GITO, 2019. URL: <http://www.encyklopaedie-der-wirtschaftsinformatik.de> (siehe S. 29, 30, 35).
- [Stu86] STURROCK, John: *Structuralism*. London: Paladin, 1986 (siehe S. 26).
- [Sun13] SUN, Yuyin; BO, Liefeng und FOX, Dieter: „Attribute Based Object Identification“. In: *IEEE International Conference on Robotics and Automation (ICRA 2013)*. Karlsruhe, 2013, S. 2096–2103. URL: <http://dx.doi.org/10.1109/ICRA.2013.6630858> (siehe S. 80, 81).
- [Sze14] SZEGEDY, Christian; LIU, Wei; JIA, Yangqing; SERMANET, Pierre; REED, Scott; ANGUELOV, Dragomir; ERHAN, Dumitru; VANHOUCHE, Vincent und RABINOVICH, Andrew: „Going Deeper with Convolutions“. In: *ArXiv e-prints* (Sep. 2014). URL: <http://arxiv.org/abs/1409.4842v1> (siehe S. 79, 83).
- [Ten09] TENORTH, Moritz und BEETZ, Michael: „KNOWROB: Knowledge Processing for Autonomous Personal Robots“. In: *Proceedings of the 2009 IEEE/RSJ International Conference on Intelligent Robots and Systems (2009)*. IEEE Press, 2009, S. 4261–4266 (siehe S. 51, 73, 74, 108).
- [Ten10] TENORTH, Moritz; KUNZE, Lars; JAIN, Dominik und BEETZ, Michael: „KNOWROB-MAP - Knowledge-Linked Semantic Object Maps“. In: *10th IEEE-RAS International Conference on Humanoid Robots (2010)*. Dez. 2010, S. 430–435. DOI: 10.1109/ICHR.2010.5686350 (siehe S. 51, 52).
- [Ten11] TENORTH, Moritz; KLANK, Ulrich; PANGERCIC, Dejan und BEETZ, Michael: „Web-Enabled Robots“. In: *IEEE Robotics Automation Magazine* 18.2 (Juni 2011), S. 58–68. DOI: 10.1109/MRA.2011.940993 (siehe S. 52, 53, 73).

- [Ten13] TENORTH, Moritz und BEETZ, Michael: „KnowRob: A Knowledge Processing Infrastructure for Cognition-Enabled Robots“. In: *International Journal of Robotics Research* 32.5 (Apr. 2013), S. 566–590. DOI: 10.1177/0278364913481635 (siehe S. 51, 53).
- [Tho18] THOSAR, Madhura; ZUG, Sebastain; SKARIA, Alpha Mary und JAIN, Akshay: „A Review of Knowledge Bases for Service Robots in Household Environments“. In: *6th International Workshop on Artificial Intelligence and Cognition (2018)*. Palermo, Italy, 2018 (siehe S. 51).
- [Uhl13] UHL, Klaus: „Semantische Kartierung und Navigation für mobile Roboter“. Diss. Karlsruhe: Karlsruher Institut für Technologie (KIT), 2013 (siehe S. 51).
- [Ver05] VERMAAK, Jaco; MASKELL, Simon und BRIERS, Mark: „A Unifying Framework for Multi-Target Tracking and Existence“. In: *Proceedings of the Eighth International Conference on Information Fusion (Fusion 2005)*. Philadelphia, PA, USA, Juli 2005, S. 250–258 (siehe S. 192, 194, 195).
- [Völ09] VÖLKER, Johanna: „Learning Expressive Ontologies“. Diss. Karlsruhe: Universität Karlsruhe (TH), 2009 (siehe S. 28, 29, 31, 35–37, 70).
- [W3C04] W3C: OWL Web Ontology Language Overview. W3C Recommendation. The World Wide Web Consortium (W3C), 2004. URL: <http://www.w3.org/TR/2004/REC-owl-features-20040210/> (siehe S. 34).
- [W3C09] W3C: OWL 2 Web Ontology Language Profiles. W3C Recommendation. The World Wide Web Consortium (W3C), 2009. URL: <http://www.w3.org/TR/2009/REC-owl2-profiles-20091027/> (siehe S. 35, 36).
- [W3C12] W3C: OWL 2 Web Ontology Language Document Overview. W3C Recommendation. The World Wide Web Consortium (W3C), 2012. URL: <http://www.w3.org/TR/2012/REC-owl2-overview-20121211/> (siehe S. 35).

- [W3C20] W3C: Time Ontology in OWL. W3C Candidate Recommendation. The World Wide Web Consortium (W3C), 2020. URL: <https://www.w3.org/TR/2020/CR-owl-time-20200326/> (siehe S. 62, 139).
- [Wes93] WEST, Mike: „Approximating Posterior Distributions by Mixtures“. In: *Journal of the Royal Statistical Society: Series B (Methodological)* 55.2 (1993), S. 409–422 (siehe S. 344–346).
- [Zad65] ZADEH, Lotfi A.: „Fuzzy Sets“. In: *Information and Control* 8.3 (1965), S. 338–353. DOI: [https://doi.org/10.1016/S0019-9958\(65\)90241-X](https://doi.org/10.1016/S0019-9958(65)90241-X) (siehe S. 39).
- [Zed13] ZEDLITZ, Jesper: „Konzeptuelle Modellierung mit UML und OWL – Untersuchung der Gemeinsamkeiten und Unterschiede mit Hilfe von Modelltransformationen“. Diss. Kiel: Christian-Albrechts-Universität, 2013 (siehe S. 20).
- [Zha14] ZHANG, Ning; DONAHUE, Jeff; GIRSHICK, Ross und DARRELL, Trevor: „Part-Based R-CNNs for Fine-Grained Category Detection“. In: *13th European Conference on Computer Vision (ECCV 2014)*. Zürich, Switzerland, 2014, S. 834–849. URL: http://dx.doi.org/10.1007/978-3-319-10590-1_54 (siehe S. 77).

Eigene Publikationen

- [1] KUWERTZ, Achim: On Adaptive Open-World Modeling Based on Information Fusion and Inductive Inference. Techn. Ber. Karlsruhe: Lehrstuhl für Interaktive Echtzeitsysteme (IES), Karlsruher Institut für Technologie (KIT), 2010.
- [2] KUWERTZ, Achim: Towards Adaptive Open-World Modeling. Techn. Ber. Karlsruhe: Lehrstuhl für Interaktive Echtzeitsysteme (IES), Karlsruher Institut für Technologie (KIT), 2011.
- [3] BELKIN, Andrey; KUWERTZ, Achim; FISCHER, Yvonne und BEYERER, Jürgen: „World Modeling for Autonomous Systems“. In: *Innovative Information Systems Modelling Techniques*. Hrsg. von KALLONIATIS, Christos. InTech, Mai 2012, S. 137–158.
- [4] KUWERTZ, Achim: Extending Object-Oriented World Modeling for Adaptive Open-World Modeling. Techn. Ber. IES-2012-06. Karlsruhe: Lehrstuhl für Interaktive Echtzeitsysteme (IES), Karlsruher Institut für Technologie (KIT), 2012.
- [5] KUWERTZ, Achim; FISCHER, Yvonne; ESSENDORFER, Barbara und PEINSIPP-BYMA, Elisabeth: „Using Context Knowledge for Maritime Situation Assessment“. In: *Proceedings of 3rd International WaterSide Security Conference (WSS 2012)*. Singapur, Mai 2012.
- [6] KUWERTZ, Achim und BEYERER, Jürgen: „Knowledge Model Quantitative Evaluation for Adaptive World Modeling“. In: *2013 IEEE International Multi-Disciplinary Conference on Cognitive Methods in Situation Awareness and Decision Support (CogSIMA), 2013*. San Diego, CA, USA, Feb. 2013, S. 91–97.

- [7] KUWERTZ, Achim und BEYERER, Jürgen: „Quantitative Measures for Adaptive Object-Oriented World Modeling“. In: *Informatik Berichte 368 - 9/2013 – Proceedings of the 4th Workshop on Dynamics of Knowledge and Belief (DKB-2013) at the 36th German Annual Conference on Artificial Intelligence, KI-2013, 2013*. Koblenz, Sep. 2013, S. 89–104.
- [8] KUWERTZ, Achim und SCHNEIDER, Gerd: „Ontology-Based Meta Model in Object-Oriented World Modeling for Interoperable Information Access“. In: *Proceedings of the Eighth International Conference on Systems (ICONS 2013)*. Sevilla, Spanien, Jan. 2013, S. 185–191.
- [9] KUWERTZ, Achim und BEYERER, Jürgen: „Dealing with Poorly Mapped Entities in Adaptive Object-Oriented World Modeling“. In: *2014 IEEE International Inter-Disciplinary Conference on Cognitive Methods in Situation Awareness and Decision Support (CogSIMA), 2014*. San Antonio, TX, USA, März 2014, S. 83–89.
- [10] KUWERTZ, Achim; GOLDBECK, Cornelius; HUG, Ronny und BEYERER, Jürgen: „Towards Web-based Semantic Knowledge Completion for Adaptive World Modeling in Cognitive Systems“. In: *Proceedings of the UKSIM-AMSS 17th International Conference on Modeling and Simulation (UKSim2015), 2015*. Cambridge, UK, März 2015, S. 165–170.
- [11] BOUVRY, Pascal; CHAUMETTE, Serge; DANOY, Grégoire; GUERRINI, Gilles; JURQUET, Gilles; KUWERTZ, Achim; MÜLLER, Wilmuth; ROSALIE, Martin und SANDER, Jennifer: „Using Heterogeneous Multilevel Swarms of UAVs and High-Level Data Fusion to Support Situation Management in Surveillance Scenarios“. In: *2016 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI 2016)*. Baden-Baden, 2016, S. 424–429. URL: <https://doi.org/10.1109/MFI.2016.7849525>.
- [12] KUWERTZ, Achim und BEYERER, Jürgen: „Extending Adaptive World Modeling by Identifying and Handling Insufficient Knowledge Models“. In: *Journal of Applied Logic* 19 (2016).

SI: Dynamics of Knowledge and Belief, S. 102–127. DOI: <https://doi.org/10.1016/j.jal.2016.05.005>.

- [13] KUWERTZ, Achim; SANDER, Jennifer; PFIRRMANN, Uwe und DYCK, Sergius: „High-Level Information Management in Joint ISR based on an Object-Oriented Approach“. In: *2017 Sensor Data Fusion: Trends, Solutions, Applications (SDF 2017)*. Bonn, 2017, S. 1–6. URL: <https://doi.org/10.1109/SDF.2017.8126360>.
- [14] KUWERTZ, Achim; MÜHLENBERG, Dirk; SANDER, Jennifer und MÜLLER, Wilmuth: „Applying Knowledge-Based Reasoning for Information Fusion in Intelligence, Surveillance, and Reconnaissance“. In: *Multisensor Fusion and Integration in the Wake of Big Data, Deep Learning and Cyber Physical System (2018)*. Cham: Springer International Publishing, 2018, S. 119–139. URL: https://doi.org/10.1007/978-3-319-90509-9_7.

Abbildungsverzeichnis

1.1	Überblick über die objektorientierte Umweltmodellierung	4
4.1	Grundsätzliche Elemente eines Hintergrundwissensmodells der objektorientierten Umweltmodellierung	113
4.2	Modellierung von probabilistischen Attributen für die adaptive Umweltmodellierung	115
4.3	Arten von probabilistischen Attributen in der adaptiven Umweltmodellierung	119
4.4	Typen von Wahrscheinlichkeitsverteilungen in der adaptiven Umweltmodellierung	120
4.5	Beispiel für die Darstellung eines probabilistischen Attributs in der Metamodellierung für die adaptive Umweltmodellierung	122
4.6	Detaillierte Modellierung von probabilistischen Relationen	126
4.7	Beispiel für die Darstellung von probabilistischen Relationen in der adaptiven Umweltmodellierung	128
4.8	Grundlegende Strukturierung von Kategorien in der Top-Level Ontologie DOLCE	130
4.9	Darstellung der Eigenschaften von Objekten in DOLCE	133
4.10	Interoperabilität und externe Schnittstellen im objektorientierten Umweltmodell	142
4.11	Modellierte Qualitäten auf Ebene des Domänenmodells für die Haushaltsdomäne	159

4.12	Modellierte Vorgänge auf Ebene des Domänenmodells für die Haushaltsdomäne	161
4.13	Modellierte Zustandsaktivitäten auf Ebene des Domänenmodells für die Haushaltsdomäne	161
4.14	Modellierte Gegenstände in der Domänen-Ontologie für die Haushaltsdomäne	163
4.15	Modellierte Rollen in der Domänen-Ontologie für die Haushaltsdomäne	164
4.16	Probabilistische Modellierung eines kardinalen Attributs im Anwendungsmodell für die Haushaltsdomäne	167
5.1	Szenario zur Demonstration der Datenassoziation	210
5.2	Demonstration der Datenassoziation	211
5.3	Erzeugen und Löschen von Repräsentanten über Schwellwerte	220
6.1	Beispielhafte Ergebnisse der Repräsentant-zu-Konzept Zuordnung	268
6.2	Beispiel für eine Repräsentant-zu-Konzept Zuordnung im inkonklusiven Fall mit ungewünschtem Normierungseffekt	270
6.3	Beispielhafte Ergebnisse der erweiterten Repräsentant-zu-Konzept Zuordnung mit A-priori-Verteilungen	278
7.1	Beispiel für die Diskretisierung eines stetigen Attributs unter Verwendung eines kleinsten unterscheidbaren Betrags	301
7.2	Attributverteilungen für die Evaluation der attributbasierten Korrespondenzmaße	303
7.3	Vergleich der attributbasierten Korrespondenzmaße	303
7.4	Entwicklung zweier Bewertungsmaße für die quantitative Modellbewertung im Demonstrationsszenario	308

8.1	Beispiele zur Verwendung der Konzeptkorrespondenz zur Detektion von schlecht beschriebenen Repräsentanten . . .	317
8.2	Zuordnungsbasiertes Detektionsmaß für schlecht beschriebene Repräsentanten	319
8.3	Abhängigkeit des zuordnungsbasierten Detektionsmaßes von der Größe der Konzeptmenge	322
8.4	Abhängigkeit des alternativen zuordnungsbasierten Detektionsmaßes von der Größe der Konzeptmenge	324
8.5	Demonstration von Detektionsmaßen für schlecht beschriebene Repräsentanten	325
8.6	Beispielhafte Generalisierung eines ordinal skalierten Attributs	343
8.7	Beispiel für die Komponentenreduktion einer Gaußmischverteilung.	348
8.8	Modellierte Verteilungen zweier stetiger Konzept-Attribute im komplexeren Evaluationsszenario . . .	355
8.9	Erzeugte A-priori-Verteilungen für die Qualitäten Länge und Breite im komplexeren Evaluationsszenario	356
8.10	Ergebnisse der quantitativen Modellbewertung und Detektionsmaße im komplexeren Evaluationsszenario . . .	358
8.11	Repräsentant-zu-Konzept Zuordnung im komplexeren Evaluationsszenario	363

Tabellenverzeichnis

5.1	Grundlegende Begriffe der Umweltmodellierung und ihre formale Darstellung.	176
6.1	Modellierte Konzepte für ein einfaches Demonstrationsszenario aus der Haushaltsdomäne	266
6.2	Beispielhafte Repräsentanten für ein einfaches Demonstrationsszenario mit zwei Attributen.	267
7.1	Beispielhafte Konzepte mit zwei Attributen zur Evaluation der Bewertungsmaße für die Konzeptkomplexität.	300
7.2	Bewertung der Attributkomplexität durch verschiedene Bewertungsmaße	301
7.3	Modellierte Konzepte im einfachen Demonstrationsszenario	306
7.4	Repräsentanten im einfachen Demonstrationsszenario in der Reihenfolge ihres Auftretens	307
8.1	Komplexitätswerte für vier ausgewählte Konzepte im komplexeren Evaluationsszenario.	359
8.2	Relevanz und prädiizierte Nützlichkeit von schlecht beschriebenen Repräsentanten im komplexeren Evaluationsszenario	360

Abkürzungsverzeichnis

DL	Description Logic
DoB	Degree of Belief
ER	Entity-Relationship
FOPL	First-order Probabilistic Languages
JPDFAF	Joint Probabilistic Data Association Filter
JSON	JavaScript Object Notation
KI	Künstliche Intelligenz
MEBN	Multi-Entity Bayesian Networks
OCL	Object Constraint Language
OOBN	Objektorientierte Bayes'sche Netze
OOWM	Objektorientiertes Umweltmodell
OPRML	Objektorientierte probabilistisch-relationale Modellierungssprache
OWL	Web Ontology Language

PRM	Probabilistisch-relationale Modelle
PR-OWL	Probabilistic OWL
QUDT	Quantities, Units, Dimensions and Data Types Ontologies
RDF	Resource Description Framework
SUMO	Suggested Upper Merged Ontology
UML	Unified Modelling Language
URI	Uniform Resource Identifier
W3C	World Wide Web Consortium
WGS84	World Geodetic System 1984
WWW	World Wide Web
XML	Extensible Markup Language

Karlsruher Schriftenreihe zur Anthropomatik (ISSN 1863-6489)

- Band 1** Jürgen Geisler
Leistung des Menschen am Bildschirmarbeitsplatz.
ISBN 3-86644-070-7
- Band 2** Elisabeth Peinsipp-Byma
Leistungserhöhung durch Assistenz in interaktiven Systemen zur Szenenanalyse. 2007
ISBN 978-3-86644-149-1
- Band 3** Jürgen Geisler, Jürgen Beyerer (Hrsg.)
Mensch-Maschine-Systeme.
ISBN 978-3-86644-457-7
- Band 4** Jürgen Beyerer, Marco Huber (Hrsg.)
Proceedings of the 2009 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory.
ISBN 978-3-86644-469-0
- Band 5** Thomas Usländer
Service-oriented design of environmental information systems.
ISBN 978-3-86644-499-7
- Band 6** Giulio Milighetti
Multisensorielle diskret-kontinuierliche Überwachung und Regelung humanoider Roboter.
ISBN 978-3-86644-568-0
- Band 7** Jürgen Beyerer, Marco Huber (Hrsg.)
Proceedings of the 2010 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory.
ISBN 978-3-86644-609-0
- Band 8** Eduardo Monari
Dynamische Sensorselektion zur auftragsorientierten Objektverfolgung in Kameranetzwerken.
ISBN 978-3-86644-729-5

- Band 9** Thomas Bader
Multimodale Interaktion in Multi-Display-Umgebungen.
ISBN 3-86644-760-8
- Band 10** Christian Frese
Planung kooperativer Fahrmanöver für kognitive Automobile.
ISBN 978-3-86644-798-1
- Band 11** Jürgen Beyerer, Alexey Pak (Hrsg.)
Proceedings of the 2011 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory.
ISBN 978-3-86644-855-1
- Band 12** Miriam Schleipen
Adaptivität und Interoperabilität von Manufacturing Execution Systemen (MES).
ISBN 978-3-86644-955-8
- Band 13** Jürgen Beyerer, Alexey Pak (Hrsg.)
Proceedings of the 2012 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory.
ISBN 978-3-86644-988-6
- Band 14** Hauke-Hendrik Vagts
Privatheit und Datenschutz in der intelligenten Überwachung: Ein datenschutzgewährendes System, entworfen nach dem „Privacy by Design“ Prinzip.
ISBN 978-3-7315-0041-4
- Band 15** Christian Kühnert
Data-driven Methods for Fault Localization in Process Technology. 2013
ISBN 978-3-7315-0098-8
- Band 16** Alexander Bauer
Probabilistische Szenenmodelle für die Luftbildauswertung.
ISBN 978-3-7315-0167-1
- Band 17** Jürgen Beyerer, Alexey Pak (Hrsg.)
Proceedings of the 2013 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory.
ISBN 978-3-7315-0212-8

- Band 18** Michael Teutsch
Moving Object Detection and Segmentation for Remote Aerial Video Surveillance.
ISBN 978-3-7315-0320-0
- Band 19** Marco Huber
Nonlinear Gaussian Filtering: Theory, Algorithms, and Applications.
ISBN 978-3-7315-0338-5
- Band 20** Jürgen Beyerer, Alexey Pak (Hrsg.)
Proceedings of the 2014 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory.
ISBN 978-3-7315-0401-6
- Band 21** Todor Dimitrov
Permanente Optimierung dynamischer Probleme der Fertigungssteuerung unter Einbeziehung von Benutzerinteraktionen.
ISBN 978-3-7315-0426-9
- Band 22** Benjamin Kühn
Interessengetriebene audiovisuelle Szenenexploration.
ISBN 978-3-7315-0457-3
- Band 23** Yvonne Fischer
Wissensbasierte probabilistische Modellierung für die Situationsanalyse am Beispiel der maritimen Überwachung.
ISBN 978-3-7315-0460-3
- Band 24** Jürgen Beyerer, Alexey Pak (Hrsg.)
Proceedings of the 2015 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory.
ISBN 978-3-7315-0519-8
- Band 25** Pascal Birnstill
Privacy-Respecting Smart Video Surveillance Based on Usage Control Enforcement.
ISBN 978-3-7315-0538-9
- Band 26** Philipp Woock
Umgebungskartenschätzung aus Sidescan-Sonar-daten für ein autonomes Unterwasserfahrzeug.
ISBN 978-3-7315-0541-9

- Band 27** Janko Petereit
Adaptive State × Time Lattices: A Contribution to Mobile Robot Motion Planning in Unstructured Dynamic Environments.
ISBN 978-3-7315-0580-8
- Band 28** Erik Ludwig Krempel
Steigerung der Akzeptanz von intelligenter Videoüberwachung in öffentlichen Räumen.
ISBN 978-3-7315-0598-3
- Band 29** Jürgen Moßgraber
Ein Rahmenwerk für die Architektur von Frühwarnsystemen. 2017
ISBN 978-3-7315-0638-6
- Band 30** Andrey Belkin
World Modeling for Intelligent Autonomous Systems.
ISBN 978-3-7315-0641-6
- Band 31** Chettapong Janya-Anurak
Framework for Analysis and Identification of Nonlinear Distributed Parameter Systems using Bayesian Uncertainty Quantification based on Generalized Polynomial Chaos.
ISBN 978-3-7315-0642-3
- Band 32** David Münch
Begriffliche Situationsanalyse aus Videodaten bei unvollständiger und fehlerhafter Information.
ISBN 978-3-7315-0644-7
- Band 33** Jürgen Beyerer, Alexey Pak (Eds.)
Proceedings of the 2016 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory.
ISBN 978-3-7315-0678-2
- Band 34** Jürgen Beyerer, Alexey Pak and Miro Taphanel (Eds.)
Proceedings of the 2017 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory.
ISBN 978-3-7315-0779-6
- Band 35** Michael Grinberg
Feature-Based Probabilistic Data Association for Video-Based Multi-Object Tracking.
ISBN 978-3-7315-0781-9

- Band 36** Christian Herrmann
Video-to-Video Face Recognition for Low-Quality Surveillance Data.
ISBN 978-3-7315-0799-4
- Band 37** Chengchao Qu
Facial Texture Super-Resolution by Fitting 3D Face Models.
ISBN 978-3-7315-0828-1
- Band 38** Miriam Ruf
Geometrie und Topologie von Trajektorienoptimierung für vollautomatisches Fahren.
ISBN 978-3-7315-0832-8
- Band 39** Angelika Zube
Bewegungsregelung mobiler Manipulatoren für die Mensch-Roboter-Interaktion mittels kartesischer modellprädiktiver Regelung.
ISBN 978-3-7315-0855-7
- Band 40** Jürgen Beyerer and Miro Taphanel (Eds.)
Proceedings of the 2018 Joint Workshop of Fraunhofer IOSB and Institute for Anthropomatics, Vision and Fusion Laboratory.
ISBN 978-3-7315-0936-3
- Band 41** Marco Thomas Gewohn
Ein methodischer Beitrag zur hybriden Regelung der Produktionsqualität in der Fahrzeugmontage.
ISBN 978-3-7315-0893-9
- Band 42** Tianyi Guan
Predictive energy-efficient motion trajectory optimization of electric vehicles.
ISBN 978-3-7315-0978-3
- Band 43** Jürgen Metzler
Robuste Detektion, Verfolgung und Wiedererkennung von Personen in Videodaten mit niedriger Auflösung.
ISBN 978-3-7315-0968-4
- Band 44** Sebastian Bullinger
Image-Based 3D Reconstruction of Dynamic Objects Using Instance-Aware Multibody Structure from Motion.
ISBN 978-3-7315-1012-3

- Band 45** Jürgen Beyerer, Tim Zander (Eds.)
**Proceedings of the 2019 Joint Workshop of
Fraunhofer IOSB and Institute for Anthropomatics,
Vision and Fusion Laboratory.**
ISBN 978-3-7315-1028-4
- Band 46** Stefan Becker
Dynamic Switching State Systems for Visual Tracking.
ISBN 978-3-7315-1038-3
- Band 47** Jennifer Sander
**Ansätze zur lokalen Bayes'schen Fusion von
Informationsbeiträgen heterogener Quellen.**
ISBN 978-3-7315-1062-8
- Band 48** Philipp Christoph Sebastian Bier
**Umsetzung des datenschutzrechtlichen Auskunftsanspruchs
auf Grundlage von Usage-Control und Data-Provenance-
Technologien.**
ISBN 978-3-7315-1082-6
- Band 49** Thomas Emter
**Integrierte Multi-Sensor-Fusion für die simultane
Lokalisierung und Kartenerstellung für mobile
Robotersysteme.**
ISBN 978-3-7315-1074-1
- Band 50** Patrick Dunau
Tracking von Menschen und menschlichen Zuständen.
ISBN 978-3-7315-1086-4
- Band 51** Jürgen Beyerer, Tim Zander (Eds.)
**Proceedings of the 2020 Joint Workshop of
Fraunhofer IOSB and Institute for Anthropomatics,
Vision and Fusion Laboratory.**
ISBN 978-3-7315-1091-8
- Band 52** Lars Wilko Sommer
Deep Learning based Vehicle Detection in Aerial Imagery.
ISBN 978-3-7315-1113-7
- Band 53** Jan Hendrik Hammer
**Interaktionstechniken für mobile Augmented-Reality-
Anwendungen basierend auf Blick- und Handbewegungen.**
ISBN 978-3-7315-1169-4

- Band 54** Jürgen Beyerer, Tim Zander (Eds.)
**Proceedings of the 2021 Joint Workshop of
Fraunhofer IOSB and Institute for Anthropomatics,
Vision and Fusion Laboratory.**
ISBN 978-3-7315-1171-7
- Band 55** Ronny Hug
Probabilistic Parametric Curves for Sequence Modeling.
ISBN 978-3-7315-1198-4
- Band 56** Florian Patzer
**Automatisierte, minimalinvasive Sicherheitsanalyse und
Vorfalreaktion für industrielle Systeme.**
ISBN 978-3-7315-1207-3
- Band 57** Achim Christian Kuwertz
**Adaptive Umweltmodellierung für kognitive Systeme in
offener Welt durch dynamische Konzepte und quantitative
Modellbewertung.**
ISBN 978-3-7315-1219-6

Lehrstuhl für Interaktive Echtzeitsysteme
Karlsruher Institut für Technologie

Fraunhofer-Institut für Optronik, Systemtechnik
und Bildauswertung IOSB Karlsruhe

In dieser Arbeit wird ein Ansatz zur adaptiven Umweltmodellierung für kognitive Systeme vorgestellt. Der Ansatz erweitert die objektorientierte Umweltmodellierung, in welcher Umgebungsinformationen schritthaltend erfasst und einem vorab definierten Domänenmodell zugeordnet werden. Im Betrieb kann dieses Domänenmodell jedoch für unvorhergesehen auftretende Entitäten unzureichend sein. Der vorgestellte Ansatz adressiert daher eine adaptive Verwaltung und Erweiterung des Domänenmodells unter Beachtung der Bedarfsgerechtigkeit und Relevanz von Modellanpassungen. Als Grundlage dafür dient eine quantitative Modellbewertung nach dem Prinzip der minimalen Beschreibungslänge, die die Repräsentationsfähigkeit eines Modells in Bezug auf den aktuellen Umgebungszustand bewertet. Auch werden ein Metamodell und eine Kern-Ontologie definiert, welche die Rahmenbedingungen für Modellanpassungen festlegen. Schließlich wird ein Regelungsschema vorgeschlagen, welches die bedarfsgetriebene Anpassung des Domänenmodells an relevante neue Entitäten durch das Erlernen von probabilistischen Konzeptdefinitionen ermöglicht.

ISSN 1863-6489
ISBN 978-3-7315-1219-6

