

Karlsruher Schriftenreihe
 Fahrzeugsystemtechnik

Markus Tesar

Deep Reinforcement Learning zur Steigerung von Energieeffizienz und Pünktlichkeit von Straßenbahnen

Markus Tesar

**Deep Reinforcement Learning zur Steigerung von
Energieeffizienz und Pünktlichkeit von Straßenbahnen**

**Karlsruher Schriftenreihe Fahrzeugsystemtechnik
Band 108**

Herausgeber

FAST Institut für Fahrzeugsystemtechnik

Prof. Dr. rer. nat. Frank Gauterin

Prof. Dr.-Ing. Marcus Geimer

Prof. Dr.-Ing. Frank Henning

Prof. Dr.-Ing. Luise Kärger

Das Institut für Fahrzeugsystemtechnik besteht aus den Institutsteilen Bahnsystemtechnik, Fahrzeugtechnik, Leichtbau und Mobile Arbeitsmaschinen.

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

Deep Reinforcement Learning zur Steigerung von Energieeffizienz und Pünktlichkeit von Straßenbahnen

von
Markus Tesar

Karlsruher Institut für Technologie
Institut für Fahrzeugsystemtechnik

Deep Reinforcement Learning zur Steigerung von
Energieeffizienz und Pünktlichkeit von Straßenbahnen

Zur Erlangung des akademischen Grades eines Doktors der
Ingenieurwissenschaften von der KIT-Fakultät für Maschinenbau des
Karlsruher Instituts für Technologie (KIT) genehmigte Dissertation
von Markus Tesar, M.Sc.

Tag der mündlichen Prüfung: 21. Oktober 2022
Erster Gutachter: Prof. Dr.-Ing. Peter Gratzfeld
Zweiter Gutachter: Prof. Dr.-Ing. Eric Sax

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-Share Alike 4.0 International License
(CC BY-SA 4.0): <https://creativecommons.org/licenses/by-sa/4.0/deed.en>*



*The cover page is licensed under a Creative Commons
Attribution-No Derivatives 4.0 International License (CC BY-ND 4.0):
<https://creativecommons.org/licenses/by-nd/4.0/deed.en>*

Print on Demand 2023 – Gedruckt auf FSC-zertifiziertem Papier

ISSN 1869-6058
ISBN 978-3-7315-1277-6
DOI 10.5445/KSP/1000155565

Kurzfassung

Eine Steigerung von Energieeffizienz und Pünktlichkeit resultiert in einer erhöhten Wirtschaftlichkeit und Leistungsfähigkeit des Bahnsystems. Diese Leistungsindikatoren können im Vollbahnbereich aufgrund der abgetrennten Bahnkörper und vorhandener Zugsicherungssysteme mit höheren Automatisierungsgraden verbessert werden. Straßenbahnen teilen sich die Trasse mit dem motorisierten Individualverkehr, Radfahrern und Fußgängern. Aus diesen Gründen sind Automatisierungsmöglichkeiten begrenzt und durch das Fahren auf Sicht sind die Fahrer von der sicheren Fahrzeugführung vereinnahmt. Fahrzeitreserven sind dagegen durch das Fahrgast- und Verkehrsaufkommen variabel. Konventionelle Optimierungsverfahren können für einzelne Szenarien Fahrprofile ermitteln, welche den Energiebedarf bei einer pünktlichen Fahrweise minimieren. Bei betrieblichen Abweichungen sind diese Fahrprofile jedoch nicht mehr optimal. Aufgrund der variablen Fahrzeiten und Haltedauern bietet sich der Einsatz von Künstlicher Intelligenz (KI) an, welche die Muster über den Tag erlernen und darauf die Fahrprofile anpassen kann.

Diese Dissertation untersucht, wie die Energieeffizienz und Pünktlichkeit von Straßenbahnen durch den Einsatz von KI gesteigert werden können. Zum Training der KI wird eine validierte Umgebung aus Messdaten aus dem regulären Fahrgastbetrieb aufgebaut. Der rechenzeitintensive Trainingsprozess wird durch ein datengetriebenes Energiebedarfsmodell beschleunigt. Auf zwei Szenarien wird die KI zu je drei Verkehrszeiten trainiert. Die ermittelten Fahrprofile werden mit denen von Fahrern aus dem regulären Fahrgastbetrieb sowie mit einem durch Dynamic Programming ermittelten theoretischen Optimum verglichen. Zur Untersuchung der Generalisierungsfähigkeiten der KI wird diese in einem ersten Schritt ohne weiteres Training auf bekannten Szenarien zu unbekanntem Haltedauern getestet und mit den Fahrern verglichen.

Im zweiten Schritt wird eine Umleitungsfahrt auf einer für die KI unbekanntem Strecke simuliert. Die berechneten Fahrprofile werden ebenfalls wieder mit Fahrern aus dem regulären Fahrgastbetrieb verglichen. Anhand der Ergebnisse werden abschließend potentielle Einsatzmöglichkeiten der KI als Fahrerassistenzsystem diskutiert.

Abstract

An increase in energy efficiency and punctuality results in improved economics and performance of the railway system. These performance indicators can be achieved with higher levels of automation in the mainline sector due to the separated tracks and existing train control systems. Trams share the track with individual motorised traffic, cyclists and pedestrians. The possibilities for automation are limited and drivers are occupied with safe vehicle guidance due to driving on sight. Driving time reserves are highly variable due to passenger and traffic volumes. Conventional optimisation methods can determine driving profiles for individual scenarios that minimise the energy demand for punctual driving. In case of operational deviations these driving profiles are no longer optimal. Due to the variable driving and stopping times, the use of artificial intelligence (AI) becomes apparent, as it can learn the patterns over the course of the day and adapt the driving profiles accordingly.

This work aims to investigate how energy efficiency and punctuality of trams can be increased through the use of AI. To train the AI, a validated environment is built from measurement data from regular passenger operation. The highly computationally intensive training process is accelerated by a data-driven energy demand model. The AI is trained on two scenarios during three traffic times. The determined driving profiles are compared with those of drivers from regular passenger operation as well as with a theoretical optimum determined by Dynamic Programming. To investigate the generalisation capabilities of the AI, it is at first tested without further training on known scenarios at unknown stopping times and compared with drivers from regular passenger operation. Secondly, a diversion journey is simulated on a route unknown to the AI. The calculated driving profiles are again compared with drivers from regular passenger operation. Finally, potential applications of the AI as a driver assistance system are discussed by means of the results.

Danksagung

Die vorliegende Dissertation entstand während meiner Tätigkeit als akademischer Mitarbeiter am Institut für Fahrzeugsystemtechnik (FAST) des Karlsruher Instituts für Technologie (KIT).

Herrn Prof. Dr.-Ing. Peter Gratzfeld danke ich für die Betreuung der Dissertation und die Übernahme des Hauptreferats. Der Freiraum zum selbstständigen und wissenschaftlichen Arbeiten sowie die konstruktiven Diskussionen haben wesentlich zum Gelingen der Dissertation beigetragen.

Ebenfalls bedanken möchte ich mich bei Herrn Prof. Dr.-Ing. Eric Sax für das Interesse an der Dissertation, dem konstruktiven Feedback zur Struktur sowie der Übernahme des Korreferats.

Herrn Prof. Dr.-Ing. Sven Matthiesen danke ich für die Übernahme des Prüfungsvorsitzes.

Für die Unterstützung im Projekt der Karlsruher Messstraßenbahn möchte ich mich bei der Albtal-Verkehrs-Gesellschaft bedanken. Speziell Achim Hettel und Marc Feistkorn haben durch ihr lösungsorientiertes Vorgehen stark zum Erfolg des Projekts beigetragen. Vielen Dank an dieser Stelle auch an meinen Kollegen Philip Otto für die äußerst produktive Zusammenarbeit in diesem Projekt.

Bei meinen Kollegen am Institutsteil Bahnsystemtechnik möchte ich mich für die tolle Arbeitsatmosphäre und die Zusammenarbeit bedanken. Vielen Dank auch an Leonie Hecke und Sebastian Reimann für die Durchsicht der Dissertation. Ebenfalls bedanken möchte ich mich bei Ivana Kramer, welche tagtäglich für einen reibungslosen organisatorischen Ablauf am Institut gesorgt hat.

Während meiner Zeit am Institut durfte ich viele Abschlussarbeiten betreuen, welche maßgeblich zum Gelingen der Dissertation beigetragen haben. Ich bedanke mich bei allen Studierenden, die mich unterstützt haben. Nennen möchte ich hier insbesondere Florian Schwarz, Stephan Leineweber, Stefan Müller-Broich, Johannes Scherm, Lars Hilmer und Björn Weckmüller.

Ganz besonders bedanken möchte ich mich bei meiner Familie und meinen Freunden für die kontinuierliche Unterstützung auf dem bisherigen Weg. Sarah, dir danke ich für deine Geduld und deinen bedingungslosen Rückhalt in den letzten Jahren.

Karlsruhe, im Oktober 2022

Markus Tesar

Inhaltsverzeichnis

Kurzfassung	i
Abstract	iii
Danksagung	v
Abkürzungsverzeichnis	xi
Symbolverzeichnis	xv
1 Einleitung und Motivation	1
1.1 Motivation	1
1.2 Stand der Technik und Wissenschaft.....	6
1.2.1 Automatisierungsgrade	7
1.2.2 Assistenzsysteme in Straßenbahnen	8
1.2.3 Berechnung energieeffizienter und pünktlicher Fahrprofile 11	
1.3 Ziel der Dissertation.....	14
1.4 Gliederung der Dissertation.....	14
2 Grundlagen	17
2.1 Maschinelles Lernen	17
2.1.1 Knowledge Discovery in Databases	18
2.1.2 Klassifikationsverfahren	20
2.1.3 Künstliche Neuronale Netze	22
2.1.4 Deep Reinforcement Learning.....	33
2.2 Dynamische Programmierung	40
2.3 Fahrwiderstände.....	41
3 Problemstellung, Bewertung, Zielsetzung und Vorgehensweise	45
3.1 Problemstellung.....	45

3.2	Bewertung und Auswahl von Methoden zur Berechnung von Fahrprofilen	48
3.3	Zielsetzung und Forschungshypothesen.....	52
3.4	Lösungsansatz und Vorgehensweise	54
4	Karlsruher Messstraßenbahn	57
4.1	Hintergründe und Grundlagen	58
4.1.1	Einordnung der Karlsruher Messstraßenbahn in den Stand der Technik und Wissenschaft.....	58
4.1.2	Datenerfassung durch die Karlsruher Messstraßenbahn....	59
4.2	Datengrundlage	61
4.2.1	Selektion	63
4.2.2	Vorverarbeitung	64
4.2.3	Transformation.....	66
4.2.4	Data Mining	69
4.2.5	Interpretation und Evaluation.....	74
4.3	Klassifikation der Fahrphasen.....	74
4.3.1	Vorgehen Klassifikation	75
4.3.2	Ergebnisse der Klassifikation der Fahrphasen	78
5	Modellierung Deep Reinforcement Learning-System.....	81
5.1	Fahrzeugmodellierung.....	82
5.1.1	Einordnung der Modellierung des Energiebedarfs in den Stand der Technik und Wissenschaft	82
5.1.2	Vorgehensweise	84
5.1.3	Modellierungsergebnisse	95
5.1.4	Diskussion.....	107
5.2	Infrastruktur- und Betriebsmodell.....	109
5.2.1	Infrastrukturmodell	109
5.2.2	Betriebsmodell	111
5.3	Aktionsraum Agent	111
5.4	Beobachtungsraum.....	112
5.5	Rewardfunktion	113
5.6	Wahl und Parametrierung des Algorithmus	116

6	Ergebnisse und Diskussion	119
6.1	Trainings- und Testszenarien	120
6.1.1	Szenario 1: Tivoli bis Kolpingplatz	120
6.1.2	Szenario 2: Glogauer Straße bis Europäische Schule.....	123
6.1.3	Szenario 3: Durlacher Tor bis Tivoli	127
6.2	Training Deep Reinforcement Learning Agent	129
6.2.1	Training Szenario 1	130
6.2.2	Training Szenario 2	132
6.3	Vergleich zwischen Deep Reinforcement Learning, Dynamic Programming und Fahrern	134
6.3.1	Optimalsteuerung mit Dynamic Programming.....	134
6.3.2	Vergleich von Energieeffizienz und Pünktlichkeit zwischen KI, Dynamic Programming und Fahrern	138
6.3.3	Klassifikation der Fahrprofile der trainierten KI	142
6.4	Auswertung Deep Reinforcement Learning Agent auf unbekanntem Szenarien	145
6.4.1	Vergleich untrainierter Haltedauern in Szenario 1.....	145
6.4.2	Vergleich untrainierter Haltedauern in Szenario 2.....	148
6.5	Deep Reinforcement Learning Agent auf unbekanntem Streckenabschnitten	151
6.6	Diskussion und kritische Würdigung.....	154
7	Zusammenfassung und Ausblick	161
7.1	Zusammenfassung	161
7.2	Ausblick.....	164
A	Anhang	169
A.1	Stand der Technik und Wissenschaft zur Automatisierung im öffentlichen Verkehr	169
A.2	Einfluss der Hyperparameter auf die Energie-bedarfsprädiktion des Fahrzeugmodells.....	172
A.3	Energiebedarfsprädiktion der Modelle auf dem Evaluationsdatensatz.....	175
A.4	Veränderte Rewardfunktion	179

A.5	Auswertung unbekannter Haltedauern	181
B	Abbildungsverzeichnis	185
C	Tabellenverzeichnis	191
D	Literaturverzeichnis	195
E	Auflistung eigener Veröffentlichungen	243

Abkürzungsverzeichnis

AStrID	Autonome S traßenbahn im D epot
AVG	A lbtal- V erkehrs- G esellschaft mbH
BOStrab	S traßenbahn B au- und Betriebsordnung
CAN	C ontroller A rea N etwork
CBTC	C ommunication B ased T rain C ontrol
CNN	C onvolutional N eural N etwork
DDPG	D eep D eterministic P olicy G radient
Deep-RL	D eep R einforcement Learning
DF	D urchschnittlicher F ahrer
DP	D ynamic P rogramming
EBO	E isenbahn- B au- und Betriebsordnung
EF	E nergieeffizientester F ahrer
EG	E uropäisches G esetz
ETCS	E uropean T rain C ontrol S ystem
FAST	Institut für F ahrzeugsystemtechnik
FHS	F ahrhebelstellung
FP	F ahrphase
FS	F altungsschichten

GoA	Grade of Automation
GPS	Global Positioning System
IEC	International Electrotechnical Commission
KDD	Knowledge Discovery in Databases
KI	Künstliche Intelligenz
KIT	Karlsruher Institut für Technologie
KNN	Künstliche Neuronale Netze
LSTM	Long-Short-Term-Memory Network
LTE	Long Term Evolution
LQR	Linear Quadratischer Regler
LZB	Linienförmige Zugbeeinflussung
MAAS	Machbarkeitsstudie von Automatisierung und Assistenzsystemen der Straßenbahn
MAPE	Mean Absolute Percentage Error
MDP	Markov Decision Process
MLP	Multilayer-Perceptron
MPC	Model Predictive Control
MPS	Multi-Physik-Simulationsmodell
NET	Niederflur Elektrotriebwagen
ODAS	Obstacle Detection Assistance System
ÖPNV	Öffentlicher Personennahverkehr

ÖV	Ö ffentlicher V erkehr
PF	P ünktlichster F ahrer
PMP	P ontryaginsches M aximum s prinzip
ReLU	R ectified L inear U nit
RMSE	R oot M ean S quare E rror
RNN	R ekurrente N euronale N etze
TD3	T win D elayed D eep D eterministic P olicy G radient
TRStrab	T echnische R egeln für S traßen b ahnen
UITP	U nion I nternationale des T ransport P ublics
V2X	V ehicle- T o- X
VVN	V oll v ernetzte S chichten

Symbolverzeichnis

Zeichen	Größe	Einheit
a	Aktion	
a	Beschleunigung	ms^{-2}
a_{Cruising}	Grenzwert für erkanntes Cruising	ms^{-2}
a_R	Radsatzabstand	m
b	Blatt des Entscheidungsbaums	
c_0	Koeffizient Fahrwiderstand	
c_1	Koeffizient Fahrwiderstand	
c_2	Koeffizient Fahrwiderstand	
c_t	Zellzustand LSTM	
E	Energiebedarf	kWh
E	Erwartungswert	
$E_{\text{Abschnitt}}$	Energiebedarf im Haltestellenabschnitt	kWh
$E_{\text{Prädiktion}}$	Prädizierter Energiebedarf	kWh
E_{Messung}	Gemessener Energiebedarf	kWh
f	Frequenz	Hz
f_t	Vergesstor LSTM	
F	Kraft	N
F_A	Anfahrwiderstand	N
F_a	Trägheitskraft	N
F_{Br}	Bremskraft	N
F_L	Laufwiderstand	N
F_{LA}	Luftwiderstand	N

F_{LR}	Rollwiderstand	N
F_{LW}	Reibungswiderstand	N
F_s	Streckenwiderstand	N
F_{SB}	Bogenwiderstand	N
F_{SG}	Steigungswiderstand	N
F_{ST}	Tunnelwiderstand	N
F_W	Gesamtfahrwiderstandskraft	N
F_x	Zugkraft	N
g	Gravitationskonstante	ms^{-2}
g_t	Interner Ausgabewert LSTM	
h	Höhe	m
i	Laufvariable	
i_t	Eingangstor LSTM	
J	Erwartungswert des Returns	
m_{Fzg}	Fahrzeugmasse	kg
m_{Leer}	Fahrzeugleermasse	kg
n	Anzahl, Laufvariable	
$n_{Passagiere}$	Anzahl Passagiere	
o_t	Ausgangstor LSTM	
$P_{Traktion}$	Traktionsleistung	kW
$P_{Coasting}$	Grenzwert für erkanntes Coasting	kW
Q	Action-Value-Funktion	
R	Bogenradius	m
R_t	Return	
r	Korrelationskoeffizient	
r	Reward	
s	Zustand	

s	Strecke	m, km
$s_{\text{Abschnitt}}$	Länge des Abschnitts	m
s_{Halt}	Distanz der Haltestelle	m
s_R	Laufkreisabstand	m
T		
t	Zeit	s
t	Knoten des Entscheidungsbaums	
$t_{\text{Abweichung}}$	Abweichung zum Fahrplan	s
$t_{\text{Berechnung}}$	Berechnungsdauer	s
t_{Fahrplan}	Vorgesehene Fahrzeit nach Fahrplan	s
t_{Fahrzeit}	Benötigte Fahrzeit zwischen Haltestellen	s
t_{Halt}	Haltedauer	s
V	Value-Funktion	
v	Geschwindigkeit	kmh ⁻¹
v_{Ende}	Ausfahrtsgeschwindigkeit	kmh ⁻¹
v_{max}	Streckenhöchstgeschwindigkeit	kmh ⁻¹
v_{Start}	Einfahrtsgeschwindigkeit	kmh ⁻¹
v_{UB}	Geschwindigkeit unteres Band	kmh ⁻¹
W	Wurzel des Entscheidungsbaums	
w	Gewichte	
x	Eingabevariable	
y	Ausgabevariable	
y_{max}	Maximal gemessene normierte Leistung	
y_{min}	Minimal gemessene normierte Leistung	
z	Grenzwert Aktivierungsfunktion	

Zeichen	Größe	Einheit
α	Steigungswinkel	rad, °
\mathfrak{B}	Replay-Buffer	
γ	Discount-Faktor	
ε	Explorationsrauschen	
η	Lernrate	
θ	Parameter Critic-Netzwerke	
\mathcal{N}	Rauschfunktion	
π	Policy	
σ	Standardabweichung	
σ^2	Varianz	
τ	Soft-Update-Faktor	
ϕ	Aktivierungsfunktion	
φ	Parameter Actor-Netzwerk	

Indizes

Zeichen	Größe
0	Startwert
i	Zählvariable
t	Zeitpunkt
π	Parameter einer Policy
ϕ	Parameter der optimalen Policy
'	Target-Netzwerke

1 Einleitung und Motivation

1.1 Motivation

Zur Erreichung der Ziele des Pariser Klimaabkommens ist die Verkehrswende von zentraler Bedeutung [224]. Der Anteil des Verkehrs am CO₂-Ausstoß beträgt in Deutschland ungefähr 20 %. Auf den Straßenverkehr entfallen davon etwa 95 %. [222] Gemessen an den Personenkilometern macht der motorisierte Individualverkehr jedoch nur 73,8 % des Modal Splits aus, der öffentliche Verkehr knapp ein Fünftel [57, 223]. Ein wesentlicher Hebel zur Senkung der CO₂-Emissionen und zu mehr Klimafreundlichkeit stellt daher die Verlagerung von Verkehren von der Straße auf die Schiene dar [15, 30, 72].

Politisch wird zur Erreichung der kurz- und langfristigen Klimaschutzziele die Stärkung des öffentlichen Verkehrs (ÖV) vorangetrieben [29, 31]. Der öffentliche Verkehr teilt sich in den Fernverkehr und den öffentlichen Personennahverkehr (ÖPNV) auf [172]. Gemessen am gesamten ÖV wurden 2019 im ÖPNV 68 % der Personenkilometer zurückgelegt und 99 % der Fahrgäste transportiert, weshalb diesem zur Erreichung der Verkehrswende eine besondere Bedeutung zukommt [3, 57, 233]. Zudem stellt der ÖPNV ein Mittel zur Mitigation der Effekte der Urbanisierung dar und steigert die Luft- und Lebensqualität in Städten sowie Ballungsgebieten [221, 222, 225].

Wo vorhanden ist die Straßenbahn ein potentiell aussichtsreicher Verkehrsträger beim Erreichen der Klimaschutzziele und der Verkehrswende. Die Straßenbahn wird elektrisch und dadurch lokal emissionsfrei betrieben. Im Gegensatz zum Dieselbus hat die Straßenbahn ein höheres Transportvolumen und geringere Umweltkosten [6, 11]. Aufgrund der Energiebereitstellung mit einem konventionellen Strommix und der Herstellung der Batterie weist ein Elektrobuss keine wesentlich besseren Umweltkosten als ein Dieselbus auf

[143, 250]. Ebenfalls schätzen die Fahrgäste den höheren Fahrkomfort der Straßenbahn gegenüber dem Bus [182].

Die Bundesregierung und die Bundesländer haben ambitionierte Ziele beim Ausbau des ÖPNV. Das Land Baden-Württemberg möchte die Fahrgastzahlen im ÖPNV bis zum Jahr 2030 verdoppeln. [145] Die Bundesregierung hat 2020 den Betreibern und Aufgabenträgern des ÖPNV durch das Gemeindeverkehrsfinanzierungsgesetz zusätzliche Gelder beim Ausbau des ÖPNV zugesichert, um die Verkehrswende weiter voranzutreiben [32].

Durch die Vielzahl an Stakeholdern von ÖPNV-Unternehmen und -Betreibern ergibt sich in einer Umfeldanalyse nach Fahey [64] und Weckmüller [244] ein Spannungsfeld, welches in Abbildung 1.1 dargestellt ist. Analysiert werden die sozialen, technologischen, ökonomischen, ökologischen und politischen Einflussfaktoren, welche auf das ÖPNV-Unternehmen einwirken.

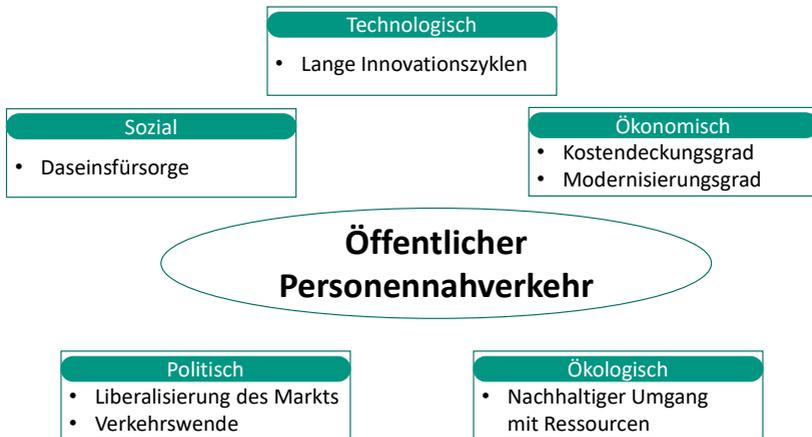


Abbildung 1.1: Spannungsfeld von ÖPNV-Unternehmen

In seiner Grundfunktion ist der ÖPNV für die Bereitstellung von finanzierbaren öffentlichen Verkehrsangeboten verantwortlich, um das *soziale* Grundrecht auf Mobilität umzusetzen [171]. Dieses Recht ist in Form der Daseinsfürsorge

im Personenbeförderungsgesetz verankert [28]. Des Weiteren haben Betreiber des ÖPNV auch eine soziale Funktion als Arbeitgeber [101].

Im Gegensatz zum Fernverkehr folgt die Erbringung der Verkehrsleistung im ÖPNV nicht nach den Gesetzen des üblichen Markts [172]. Verkehrsunternehmen sind auf Förderungen und Vorgaben der öffentlichen Hand und weiteren Interessensgruppen angewiesen, die die Gestaltung der Leistungen beeinflussen [171]. Grundsätzlich sind die Verkehrsunternehmen dazu angehalten, möglichst *eigenwirtschaftlich* zu arbeiten. Eine Kenngröße hierfür ist der Kostendeckungsgrad, welcher ermittelt, welchen Anteil die jährlichen Erträge an den gesamten Aufwendungen leisten. Typische Kostendeckungsgrade im deutschen ÖPNV bewegen sich in den letzten Jahren zwischen 75 und 80 %. [232] Eine weitere Kenngröße ist der Modernisierungsgrad, welcher ein Indikator für zukünftige Investitionen in die Infrastruktur und die Fahrzeuge darstellt. Dieser liegt im Bundesdurchschnitt aktuell bei knapp 63 %. [48]

Aus einer *technologischen* Sicht ist im Schienenfahrzeugsektor der lange Betrieb der Fahrzeuge ein generelles Hindernis, bis neue Entwicklungen einfließen können. Fahrzeuge werden teils mehr als 30 Jahre betrieben, so dass Innovationszyklen langwierig verlaufen. Dies beeinflusst unter anderem flottenweite Digitalisierungsstrategien. [123]

Politisch werden ÖPNV-Unternehmen zwar gefördert, durch die Liberalisierung des Markts jedoch zusätzlich unter Druck gesetzt. Durch die seit 2009 geltende *Verordnung EG 1370/2007* werden zur Vergabe von Verkehrsdienstleistungen wettbewerbliche Ausschreibungen genutzt. [62] Dadurch stehen traditionelle ÖPNV-Unternehmen in Konkurrenz zu anderen Bietern, welche eine kostengünstigere Erbringung der Verkehrsleistung anbieten können.

Aus *ökologischer* Sicht ist der ÖPNV ein Aushängeschild zum nachhaltigen Umgang mit Ressourcen. Hier gilt es, eine sozialverträgliche und klimafreundliche Mobilitätswende voranzutreiben. [29, 31] Zusätzlich wird mehr öffentlicher Verkehr von der Bevölkerung und der Politik gefordert [145].

Dennoch kann die Verkehrswende nur gelingen, wenn die Verkehrsunternehmen ein attraktives Angebot stellen und dieses auch von den Endkunden an-

genommen wird. Dadurch kann ein nachhaltiger Wechsel weg vom motorisierten Individualverkehr hin zum ÖPNV gelingen. [231]

Fahrgäste fordern für den Umstieg ein pünktliches und hochverfügbares System [168, 226]. Eine mangelnde Pünktlichkeit ist dabei Hauptkritikpunkt vieler Nutzer des ÖPNV [116, 195]. Betreiber und Unternehmen können jedoch zur Steigerung der Pünktlichkeit und der Verfügbarkeit nicht unbegrenzt neue Fahrzeuge beschaffen, die Infrastruktur ausbauen und neue Fahrer¹ einstellen. Dadurch könnte der Fahrplan verdichtet werden, so dass Verspätungen weniger problematisch sind. Anbieter der Verkehrsdienstleistungen müssen jedoch weiter wirtschaftlich im Sinne des Kostendeckungsgrades handeln und dabei gleichzeitig die Pünktlichkeit und Verfügbarkeit steigern, um attraktiv zu bleiben. [43, 252]

Effizienzsteigerungen können auf Systemebene durch die Automatisierung und den Einsatz von Fahrerassistenzsystemen erreicht werden. Fahrerassistenzsysteme geben dem Fahrer eine Geschwindigkeitsvorgabe für den jeweiligen Streckenabschnitt mit dem Ziel, die Energieeffizienz und die Pünktlichkeit zu steigern. Die Systeme greifen jedoch nicht aktiv in die Fahrzeugsteuerung ein und der Fahrer ist nicht gezwungen, die Vorgabe umzusetzen. Im Gegensatz zu automatisierten Systemen reduzieren sich dadurch die Anforderungen an die Zulassung von Fahrerassistenzsystemen. [50, 154] Weitere Effizienzsteigerungen sind in der Instandhaltung möglich durch den Einsatz von zustandsbasierter Instandhaltung zur Erhöhung der Verfügbarkeiten und der Reduzierung der Instandhaltungszeiten [79, 111].

Beides sind prädestinierte Felder für den Einsatz datengetriebener Methoden und lernfähiger Systeme [83]. Die effiziente und zielgerichtete Nutzung großer Datenmengen wird als Effizienztreiber des 21. Jahrhunderts gesehen [142]. Die Daten liefern die Basis zur Implementierung von Systemen des Maschinellen Lernens und der Künstlichen Intelligenz. Diese Forschungsfelder

¹ Aus Gründen der Lesbarkeit wird im Text das generische Maskulinum verwendet. Gemeint sind jedoch stets alle Geschlechter.

werden als Schlüsseltechnologie für das Fahrzeug der Zukunft angesehen. [2, 134, 151, 155, 219].

Das Bahnsystem ist durch die Spurführung für eine Automatisierung prädestiniert. Insbesondere bei Straßenbahnen sind diese Automatisierungsmöglichkeiten jedoch noch nicht ausgeschöpft. Straßenbahnen fahren überwiegend auf Sicht oder mit zusätzlicher Signalisierung, d.h. der Fahrer passt selbstständig die Geschwindigkeit den jeweiligen betrieblichen Gegebenheiten oder Vorgaben an. Ein erfolgsversprechender Ansatz zur Steigerung von Energieeffizienz und Pünktlichkeit ist die Anpassung der Geschwindigkeitstrajektorie des Fahrzeugs. Je nach verfügbarer Fahrzeitreserve kann die Fahrstrategie hinsichtlich maximaler Energieeffizienz und Pünktlichkeit adaptiert werden. Dies führt zu einer Reduzierung des Energiebedarfs und einer Steigerung der Pünktlichkeit. [85]

In Bahnsystemen mit abgetrennten Bahnkörpern konnten mit Assistenzsystemen und einem höheren Automatisierungsgrad bereits signifikante Energieeffizienz- und Pünktlichkeitssteigerungen bewirkt werden [149]. Im Straßenbahnbereich teilt sich die Bahn jedoch zum Teil die Trasse mit dem motorisierten Individualverkehr, Radfahrern und Fußgängern. Dadurch gestaltet sich die Fahrzeitreserve variabler als bei Bahnen mit separatem Gleiskörper oder in abgeschlossenen Systemen. Fahrer können durch ihre jahrelange Erfahrung diese Vorgänge zum Teil einschätzen und eine energieeffiziente und pünktliche Fahrstrategie umsetzen. Durch die Auswirkungen des Individualverkehrs und der nicht vorhandenen Automatisierung sind die Fahrer jedoch häufig von der sicheren Fahrzeugführung vereinnahmt und stellen die Aspekte der Energieeffizienz und Pünktlichkeit in den Hintergrund. [153, 218] Des Weiteren erhalten Fahrer während des täglichen Betriebs keine Rückmeldung zur benötigten Energie für die Traktion des Fahrzeugs. Um sowohl sicher als auch pünktlich und zugleich energieeffizient fahren zu können, benötigen die Fahrer ein Assistenzsystem, welches ihnen möglichst einfach und intelligent eine Geschwindigkeitsvorgabe für den je-

weiligen Streckenabschnitt in Abhängigkeit der aktuellen betrieblichen Situation geben kann. Konventionelle deterministische Ansätze stoßen hier an ihre Grenzen. Durch verschiedene äußere und innere Einflüsse hat das Gesamtsystem zu viele Freiheitsgrade, um angepasst auf eine individuelle Fahrsituation in Echtzeit eine Geschwindigkeitsvorgabe berechnen zu können. Ansätze, die auf Künstlicher Intelligenz basieren, können wiederum als lernfähige Systeme betriebliche Einflüsse erlernen. Auf Basis des erlernten Wissens können energieeffiziente und pünktliche Fahrprofile berechnet und den Fahrern vorgegeben werden. Fahrzeugführer können ebenfalls von einem solchen Assistenzsystem lernen, genauso wie dieses alle Fahrer in unerwarteten und ungewohnten Betriebssituationen unterstützt.

Bezogen auf das dargestellte Spannungsfeld in Abbildung 1.1 kann eine erfolgreiche Umsetzung eines solchen Assistenzsystems zu positiven Implikationen in allen aufgeführten Bereichen führen. Aus ökonomischer Sicht kann durch Einsparungen des Energiebedarfs sowie durch die gesteigerte Attraktivität des Systems und den damit einhergehenden erhöhten Fahrgeldeinnahmen der Kostendeckungsgrad erhöht werden. Dies führt wiederum zum politischen Ziel der Verkehrswende und ökologisch zu einem schonenderen Ressourcenumgang. Technologisch lassen sich solche Systeme auch in Bestandsfahrzeuge integrieren, weshalb nicht auf Neubeschaffungen gewartet werden muss. Sozial kann dadurch weiterhin die Funktion der Daseinsfürsorge erfüllt und verbessert sowie eine finanzierbare Mobilitätsdienstleistung angeboten werden. Des Weiteren werden Fahrer während ihres Arbeitsalltags durch ein intelligentes Assistenzsystem entlastet.

1.2 Stand der Technik und Wissenschaft

Mit Fahrerassistenzsystemen und einem höheren Automatisierungsgrad können die Energieeffizienz, der Fahrkomfort, die Sicherheit und die Pünktlichkeit erhöht werden [154, 178]. In einer Befragung von Verkehrsbetrieben erhof-

fen sich 60 % der Betriebe mit dem Einsatz von Assistenzsystemen und Automatisierung eine höhere Pünktlichkeit sowie eine höhere Energieeffizienz. Weitere 20 % wünschen sich eine Entlastung der Fahrer während des täglichen Betriebs und eine dadurch induzierte erhöhte Sicherheit des Systems Straßenbahn [149].

Kapitel 1.2 umfasst den Stand der Technik und Wissenschaft zum Einsatz von Assistenzsystemen in Straßenbahnen sowie zur Berechnung energieeffizienter und pünktlicher Fahrtrajektorien. Der Stand der Technik und der Wissenschaft zur Automatisierung des gesamten öffentlichen Verkehrs findet sich als übergeordnete Betrachtung in Anhang A.1. Die Einordnung des Forschungsprojekts der Karlsruher Messstraßenbahn in den Stand der Technik erfolgt in Kapitel 4.1.1. Die datengetriebene Energiebedarfsmodellierung wird in Kapitel 5.1.1 in den Stand der Technik und Wissenschaft eingeordnet.

1.2.1 Automatisierungsgrade

Der Weltverband für öffentliches Verkehrswesen (UITP) definiert in der IEC-Norm 62290 fünf verschiedene Automatisierungsgrade (engl.: Grade of Automation, GoA) für das Bahnsystem [103].

GoA 0 repräsentiert das *Fahren auf Sicht* in einem manuellen Zugbetrieb. Es gibt keine Signalisierung und keine Zugsicherungssysteme. Die gesamte Kontrolle und Verantwortung obliegen dem Fahrer des Fahrzeugs. [103]

GoA 1 stellt die *manuelle Fahrt* mit einer Überwachung durch ein Zugbeeinflussungssystem dar. Der Fahrer ist für die Steuerung des Fahrzeugs zuständig, jedoch kann das Zugbeeinflussungssystem bei Geschwindigkeitsüberschreitungen eingreifen und den Zug in einen sicheren Zustand überführen. [103]

GoA 2 ist der *halbautomatische Zugbetrieb*, bei welchem die Steuerung der Längsbewegung des Fahrzeugs durch ein technisches System übernommen

wird. Der Fahrer ist weiterhin im Führerstand, um die Türsteuerung zu bedienen und den Fahrgastwechsel in den Stationen zu überwachen. Ebenfalls kann in Gefahrensituationen durch den Fahrer eingegriffen werden. [103]

GoA 3-Systeme setzen einen *begleiteten fahrerlosen Zugbetrieb* um, für welchen kein Fahrer im Führerstand erforderlich ist. In Notsituationen kann der Zugbegleiter die Fahrzeugsteuerung übernehmen. Die Türfreigabe und die Überwachung des Fahrgastwechsels liegen ebenfalls in der Verantwortung des Zugbegleiters. [103]

GoA 4 steht für den *vollautomatischen fahrerlosen Zugbetrieb*. Der Zug kann ohne Begleitpersonal betrieben werden. Der Fahrgastwechsel kann unter anderem durch Kamerasysteme an Bahnsteigen aus der Ferne überwacht werden. [103]

1.2.2 Assistenzsysteme in Straßenbahnen

Straßenbahnen werden in einem urbanen Verkehrsumfeld mit Mischverkehr eingesetzt. Dadurch ist eine Automatisierung erheblich schwerer umzusetzen als bei Vollbahnen oder Metros mit abgetrennten und unabhängigen Bahnkörpern. Straßenbahnen fahren meist auf Sicht, was einem GoA der Stufe 0 entspricht. Erst ab definierten Geschwindigkeiten, in Deutschland ab 70 km/h, sowie in Tunneln ist eine Signalisierung vorgesehen. In diesen Fällen wird die Straßenbahn mit GoA 1 betrieben. Um die Fahrer während des täglichen Betriebs zu unterstützen, arbeiten mehrere Verkehrsbetriebe, Unternehmen und Forschungseinrichtungen an Lösungen.

Im Fokus stehen dabei Assistenzsysteme, welche die Fahrer in ihrer Sicherheitsaufgabe unterstützen und dabei zur Unfallvermeidung mit anderen Verkehrsteilnehmern beitragen sollen [227]. Hersteller greifen dabei auf etablierte Sensortechnologien aus dem Automobilbereich zurück [112]. Die Straßenbahnen werden mit Lidar- [160] und Radarsensoren [238] sowie mit

Kamerasystemen [128] ausgerüstet, um Objekte und Personen im Nahbereich der Straßenbahn zu detektieren, welche einen Unfall verursachen könnten.

Die erste flächendeckende Implementierung von Kollisionswarnsystemen erfolgte 2015 bei der Verkehrsgesellschaft Frankfurt am Main [235]. 73 Fahrzeuge wurden mit dem *Obstacle Detection Assistance System* (ODAS) [68] des damaligen Herstellers Bombardier Transportation mit einem Stereokamerasystem ausgerüstet [82]. Dieses System kommt ebenfalls in 30 Fahrzeugen in Dresden zum Einsatz [251]. Des Weiteren vertreiben Bosch und Continental Assistenzsysteme zur Kollisionswarnung in Straßenbahnen [39, 52]. Siemens verbaut mit dem Tram Assistant ebenfalls ein Kollisionswarnsystem in den Straßenbahnfahrzeugen der Avenio-Baureihe. Diese Assistenzsysteme werden serienmäßig in Kopenhagen, Den Haag, Bremen und Ulm eingesetzt. [95]

Fahrerassistenzsysteme werden als Brückentechnologie für höher automatisierte oder autonome Straßenbahnen angesehen [152]. 2018 wurde von Siemens ein erster Prototyp einer autonomen Tram vorgestellt, welche auf Funktionen des Tram Assistant zurückgreift [159, 190]. Das darauf aufbauende Forschungsprojekt mit Beteiligung der Siemens Mobility GmbH und dem Karlsruher Institut für Technologie (KIT) *Autonome Straßenbahn im Depot (AStriD)* untersucht, wie erste GoA 3- und GoA 4-Fahrfunktionen im Straßenbahndepot implementiert werden können [107].

Das Fachgebiet Fahrzeugtechnik der TU Darmstadt forscht zusammen mit der HEAG mobilo GmbH im Projekt zur *Machbarkeitsstudie von Automatisierung und Assistenzsystemen der Straßenbahn (MAAS)* [49]. Dabei werden Möglichkeiten zur Implementierung von Assistenzsystemen und höheren Automatisierungsgraden durch den Einsatz von etablierten Sensortechnologien und Algorithmen aus dem Kraftfahrzeugbereich evaluiert. Ebenfalls werden Potentiale zum Einsatz der Teleoperation von Straßenbahnen untersucht [105, 204].

Es zeigt sich, dass insbesondere im Straßenbahnbereich durch Implementierungen von Assistenzsystemen eine Steigerung der Sicherheit vorgenommen wird. Zusätzlich gibt es erste Untersuchungen in Forschungsprojekten zu hochautomatisierten Straßenbahnen. Diese sind jedoch noch weit entfernt von einer Serienanwendung und haben durch den Einsatz von Maschinellen Lernverfahren erhebliche Hürden in der Zulassung. Dabei werden Entscheidungen mit Neuronalen Netzen getroffen und diese greifen aktiv in die Fahrzeugsteuerung ein. [96]

Aktuelle Defizite bei Assistenzsystemen in der Straßenbahn

Bisherige Systeme in Straßenbahnen fokussieren sich nicht auf die Steigerung von Energieeffizienz und Pünktlichkeit. Im Vollbahn- und Metrobereich werden bereits Assistenzsysteme oder ein höherer Automatisierungsgrad umgesetzt (vgl. Kapitel A.1). Dadurch wird eine pünktlichere und energieeffizientere Fahrweise ermöglicht. Dabei ist jedoch stets ein Zugsicherungssystem vorhanden. Aktuelle Implementierungen setzen auf die Umsetzung von automatisierten Fahrfunktionen über die Zugsicherungssysteme des European Train Control Systems (ETCS) oder dem Communication Based Train Control (CBTC) [7, 58, 200]. Beispielhafte Projekte hierfür sind der automatisierte Betrieb der S-Bahn in Hamburg sowie in London auf der Thameslink-Strecke, bei denen jeweils an GoA2-angelehnte Fahrfunktionen umgesetzt werden [24, 185].

Der Einsatz dieser Zugsicherungssysteme zum automatisierten Betrieb von Straßenbahnen ist aufgrund des urbanen Mischverkehrs nicht möglich. Zur Steigerung der Energieeffizienz setzen Verkehrsbetriebe bislang lediglich auf Fahrerschulungen [132]. Da die Fahrer während des täglichen Betriebs jedoch hauptsächlich von ihrer Sicherheitsaufgabe vereinnahmt sind und kein Feedback zum Energiebedarf erhalten [218], sind Lösungen zu erarbeiten, die die Fahrer bei der energieeffizienten und pünktlichen Fahrzeugführung unterstützen.

1.2.3 Berechnung energieeffizienter und pünktlicher Fahrprofile

Das grundlegende Optimierungsproblem zum energieeffizienten und pünktlichen Betrieb von Schienenfahrzeugen ist durch nichtlineare Dynamiken des Antriebsstrangs und der Fahrwiderstände als Funktion der Geschwindigkeit charakterisiert [179].

In der Literatur gibt es verschiedene Ansätze zur analytischen Berechnung von Fahrprofilen. Scheepmaker gibt einen Überblick über die Theorie und den Stand der Forschung zur Berechnung von energieoptimalen Geschwindigkeitsprofilen [179].

Es wird zwischen fünf Lösungsansätzen unterschieden. Der erste Lösungsansatz basiert auf der Theorie der optimalen Steuerung [74, 163]. Zur Steuerung werden vier Zustände definiert. Diese umfassen das Beschleunigen mit der maximal möglichen Beschleunigung, die Beharrungsfahrt bei konstanter Geschwindigkeit, das Ausrollen des Fahrzeugs und das Abbremsen mit der maximal möglichen Verzögerung. Zur Berechnung des Energiebedarfs wird ein vereinfachtes, rein auf Fahrwiderständen basierendes Energiebedarfsmodell verwendet. Mittels einer quadratischen Zielfunktion werden durch einen *linear quadratischen Regler* die optimalen Umschaltzeitpunkte zwischen den vier Zuständen ermittelt. Dieses Optimierungsproblem entspricht der Lösung der algebraischen Riccati-Gleichung. Aus der Berechnung resultiert eine unter den gegebenen Randbedingungen energieoptimale und pünktliche Fahrtrajektorie. [4, 5] Solche linear quadratischen Regler weisen Einschränkungen bei der Berücksichtigung weiterer Randbedingungen auf. Dadurch ergeben sich bei diesem Verfahren Schwierigkeiten, wenn zwischen regenerativem und nicht regenerativem Bremsen differenziert wird, oder Steigungen exakt modelliert werden [166, 174]. Aufgrund dessen und der Vereinfachungen des Energiebedarfsmodells kann das Ergebnis vom tatsächlichen Optimum abweichen. Ein valider Vergleich mit Fahrern aus dem regulären Fahrgastbetrieb ist nicht möglich. [179]

Die zweite Möglichkeit zur Ermittlung energieeffizienter und pünktlicher Fahrtrajektorien stellt der Einsatz von *Metaheuristiken* dar. Durch Metaheuristiken werden Optimierungsprobleme näherungsweise gelöst [1]. Die verwendeten Optimierungsalgorithmen können dabei problemübergreifend angewendet werden [1]. Anstatt die optimalen Umschaltzeitpunkte zwischen den vier Fahrzuständen mittels eines linear quadratischen Reglers zu berechnen, werden evolutionäre [35], genetische [127, 189] oder naturinspirierte Algorithmen [137] verwendet. Da die grundlegende Formulierung des Optimierungsproblems identisch zu den indirekten analytischen Ansätzen ist, kann auch das Ergebnis von Heuristiken vom tatsächlichen Optimum abweichen. Dadurch ist für dieses Verfahren ein valider Vergleich mit realen Messdaten ebenfalls nicht möglich. [179]

Der dritte Lösungsansatz ist die *modellprädiktive Regelung* (engl.: Model Predictive Control, MPC). Dieser Ansatz wird in [239-241] verwendet und zeigt eine Verbesserung der Ergebnisqualität gegenüber den bislang angeführten Ansätzen durch eine genauere Modellierung des Fahrzeugs und der Umgebung. Im Gegensatz zum Riccati-Regler können beim MPC beliebige Randbedingungen zur Optimierung hinzugezogen werden. Zudem wird die Geschwindigkeitstrajektorie nicht über Optimierung der Umschaltzeitpunkte zwischen vier Zuständen ermittelt. Es können beliebige Beschleunigungen und Verzögerungen gewählt werden. Eine Herausforderung bei MPC ist die höhere Rechenzeit zur Kalkulation der optimalen Geschwindigkeitstrajektorien. Je nach Länge des gewählten Prädiktionshorizonts verbessert sich die Berechnung, was jedoch mit einer erhöhten Rechendauer einhergeht. [187] Durch die Möglichkeit einer validen Modellierung können Vergleiche mit Fahrern aus dem regulären Fahrgastbetrieb vorgenommen werden. [179]

Energieoptimale und pünktliche Fahrtrajektorien können ebenfalls durch den Einsatz von *Deep Reinforcement Learning* (Deep-RL) ermittelt werden. Im Bereich der Schienenfahrzeuge werden erste Untersuchungen zum Einsatz von Deep-RL-Agenten in Metro- und Vollbahnanwendungen durchgeführt [144, 237, 253]. Die wählbaren Aktionen des Agenten in diesen Forschungsarbeiten

sind die Beschleunigungen. Bei den bisherigen Ansätzen ist der Aktionsraum durch die Diskretisierung jedoch eingeschränkt und es werden keine validen Energiebedarfsmodelle genutzt. Zudem werden Steigungen und Kurvenradien nicht konform der Standards zur Bestimmung des Energiebedarfs von Schienenfahrzeugen [47] modelliert. Die ermittelten Fahrprofile werden nicht mit menschlichen Fahrern verglichen und lediglich innerhalb des trainierten Szenarios ausgewertet. [144, 237, 253]

Die Berechnungsdauer der Fahrprofile von trainierten Deep-RL-Agenten ist gering. Zudem ist es denkbar, dass nicht für jede Fahrzeitreserve eine neue Optimierung durchgeführt werden muss, sondern ein Wissenstransfer innerhalb der Szenarien stattfindet, da Deep-RL ein lernfähiges System ist. [254] Bei Einhaltung von Modellierungsstandards können ebenfalls quantitative Vergleiche mit Fahrern aus dem regulären Fahrgastbetrieb durchgeführt werden.

Der fünfte Ansatz aus der Theorie der optimalen Steuerung ist *Dynamic Programming* nach Bellmann. Die Berechnung der optimalen Fahrtrajektorie erfolgt rekursiv aus den Teillösungen, welche während der Berechnung in jedem Zeitschritt zwischengespeichert werden. Die Ermittlung sämtlicher Teillösungen in den einzelnen Zeitschritten ist rechenzeitintensiv, wodurch der Algorithmus nicht onlinefähig ist. Durch die Berechnung aller Teillösungen garantiert der Algorithmus ein globales Optimum. Franke [75] zeigt, dass im Gegensatz zu linear quadratischen Reglern die Ergebnisse signifikant verbessert werden können. Larranaga [124] optimiert die Fahrprofile von Metrofahrzeugen mit Dynamic Programming. Mit einem vereinfachten Aktionsraum kann die Berechnungsdauer auf eine Stunde für ein optimales Fahrprofil reduziert werden. Haahr [87] erweitert diesen Ansatz um örtliche Fixpunkte, die bis zu einer gewissen Zeit erreicht werden müssen. Dadurch reduziert sich die Anzahl an Lösungen und die zu berechnenden Zwischenschritte.

Bei der Verwendung von Dynamic Programming müssen keine Modellvereinfachungen durchgeführt werden. Ebenso gibt es keine Beschränkungen bei der Hinzunahme von weiteren Randbedingungen. Insofern valide Energiebe-

darfs- und Infrastrukturmodelle verwendet werden, ist ein Abgleich mit Messdaten aus dem realen Fahrgastbetrieb möglich. Nachteilig am Verfahren ist jedoch die fehlende Onlinefähigkeit. [87]

1.3 Ziel der Dissertation

Ziel dieser Dissertation ist die Steigerung von Energieeffizienz und Pünktlichkeit von Straßenbahnen. In Abhängigkeit der betrieblichen Situation können Fahrer während des täglichen Betriebs bei einer energieeffizienten und pünktlichen Fahrweise unterstützt werden. Damit können sich die Fahrer auf ihre primäre Sicherheitsaufgabe fokussieren. Dazu wird in dieser Dissertation erforscht, wie speziell softwareseitig ein KI-basiertes Fahrerassistenzsystem einen Beitrag zur Energieeffizienz und Pünktlichkeit liefern kann. Gegenstand der Forschung ist, welches Berechnungsverfahren unter den variablen Randbedingungen der Straßenbahn einen energieeffizienten und pünktlichen Betrieb ermöglicht.

Ein weiteres Ziel der Dissertation ist die Quantifizierung der Steigerung der Energieeffizienz und Pünktlichkeit im Vergleich zu Fahrern aus dem regulären Fahrgastbetrieb. Untersucht wird deshalb, welche Arten der Fahrzeugmodellierung sich für den Einsatz im Fahrerassistenzsystem eignen und dabei onlinefähige Berechnungen der Fahrprofile ermöglichen.

1.4 Gliederung der Dissertation

Anhand von Abbildung 1.2 wird die Gliederung der Dissertation verdeutlicht. Im nachfolgenden Kapitel 2 werden die theoretischen Grundlagen erläutert. Zunächst werden ein Prozess zur systematischen Extraktion von Wissen aus Daten sowie exemplarische Klassifikationsverfahren vorgestellt, die zur automatisierten Zuordnung der Fahrweise von Straßenbahnfahrern aus dem täglichen Betrieb verwendet werden. Daran anschließend wird ein Überblick

über die Grundlagen zu verschiedenen Arten von Künstlichen Neuronalen Netzen (KNN) gegeben. Darauffolgend werden die theoretischen Grundlagen zu Deep Reinforcement Learning als Kernstück der Dissertation sowie Dynamic Programming als Vergleichsalgorithmus zum Deep Reinforcement Learning beleuchtet. Anschließend werden die Grundlagen zu Fahrwiderständen behandelt.

Im anschließenden Kapitel 3 wird aufbauend auf dem Stand der Technik und Wissenschaft sowie den theoretischen Grundlagen die Zielsetzung der Dissertation konkretisiert. Anhand von Bewertungskriterien werden verschiedene Lösungsansätze zur Berechnung energieeffizienter und pünktlicher Fahrprofile miteinander verglichen und ein Verfahren zur softwareseitigen Implementierung ausgewählt. Für das ausgewählte Verfahren werden Forschungshypothesen aufgestellt, anhand derer der Lösungsansatz sowie die Vorgehensmethodik abgeleitet werden.

Kapitel 4 beschäftigt sich mit dem Kooperationsprojekt der Karlsruher Messstraßenbahn. Zunächst wird das Forschungsprojekt vorgestellt und anschließend die Datengrundlage erarbeitet, auf welcher die Modellierung des Deep Reinforcement Learning-Systems und des Trainings der Agenten fußt.

Im Kapitel 5 wird ein Deep Reinforcement Learning-System modelliert, welches aus dem gesamten Karlsruher Bahnsystem besteht. Die Teilsysteme werden durch Messdaten der Karlsruher Messstraßenbahn validiert.

Das Kapitel 6 umfasst das Training und den Test der Deep Reinforcement Learning-Agenten auf verschiedenen Szenarien sowie einen Abgleich mit einem durch Dynamic Programming ermittelten theoretischen Optimum und Fahrern aus dem regulären Fahrgastbetrieb.

Abschließend werden die Ergebnisse dieser Dissertation zusammengefasst und ein Ausblick auf weitere mögliche Forschungsschwerpunkte gegeben.

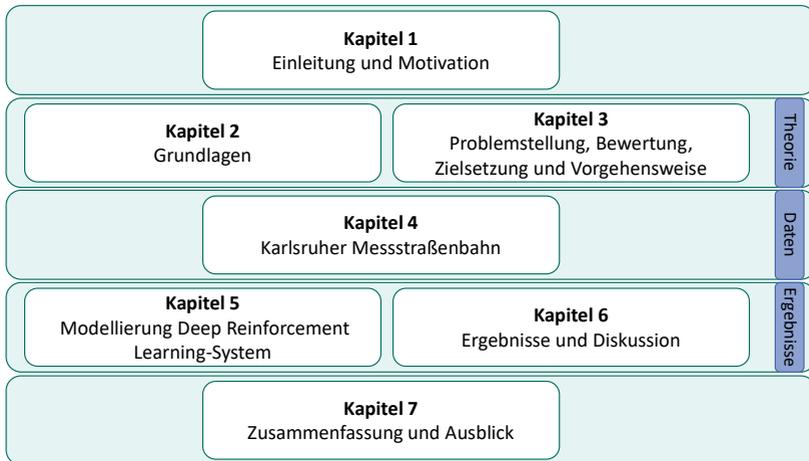


Abbildung 1.2: Übersicht zur Struktur und der inhaltlichen Aufgliederung der Dissertation

2 Grundlagen

In diesem Kapitel erfolgt die Einführung in die theoretischen Grundlagen der Dissertation. Zu Beginn des Kapitels werden zunächst verschiedene überwachte Maschinelle Lernverfahren zur Klassifikation und Regression erläutert. Anschließend werden die Grundlagen zum Deep Reinforcement Learning sowie der in der Dissertation verwendete *Twin Delayed Deep Deterministic Policy Gradient*-Algorithmus detailliert. Darauf folgend wird Dynamic Programming als Optimalsteuerungsverfahren beleuchtet. Abschließend werden die Grundlagen zu Fahrwiderständen von Schienenfahrzeugen erläutert.

2.1 Maschinelles Lernen

Maschinelles Lernen stellt ein Teilgebiet der Künstlichen Intelligenz dar, welches dazu verwendet wird, Muster und Modelle aus zumeist großen Datenmengen abzuleiten [60]. Durch das Training von Algorithmen erlernen Maschinen Vorgehensweisen, für die sie nicht explizit programmiert worden sind [51]. Diese Modelle können nach ihrem Training auf potentiell unbekannte Datensätze angewandt werden [40].

Grundsätzlich wird zwischen drei verschiedenen Trainingsansätzen beim Maschinellen Lernen differenziert, dem überwachten, dem unüberwachten und dem bestärkenden Lernen [60].

Beim überwachten Lernen (engl.: supervised learning) erlernt der Algorithmus Zusammenhänge anhand gegebener Kombinationen aus Dateninputs und -outputs. Mit den trainierten Modellen können in neuen Datensätzen die Zieldaten präzisiert werden. Überwachte Lernverfahren kommen in Regressions- und Klassifikationsanwendungen zum Einsatz. [60]

Unüberwachte Lernverfahren (engl.: unsupervised learning) haben im Gegensatz zu überwachten Lernverfahren keine Input-Output-Kombinationen zum

Training zur Verfügung. Die Algorithmen suchen inhärente Muster und Strukturen im Datensatz und versuchen Gruppierungen zu identifizieren. Typische Anwendungsfälle für unüberwachte Lernverfahren sind Clusterverfahren und die Dimensionsreduktion von Input-Daten zur Reduzierung des Datensatzes auf wesentliche Parameter. [60]

Beim bestärkenden Lernen (engl.: Reinforcement Learning) wird nicht durch einen gegebenen Datensatz gelernt, sondern durch Interaktionen mit der Umwelt. Auf Basis dieser Interaktionen erlernt eine KI optimales Verhalten anhand einer vordefinierten Zielfunktion. Bestärkendes Lernen wird zur Steuerung und Regelung sowie zur Optimierung eingesetzt. [60]

2.1.1 Knowledge Discovery in Databases

Die Qualität der Ergebnisse von Modellen des Maschinellen Lernens korrelieren mit der Qualität des Dateninputs [109]. Zur systematischen Extraktion von Wissen aus Datenbeständen kann der Knowledge Discovery in Databases (KDD)-Prozess nach Fayyad [66] angewendet werden. Mit diesem Prozess kann zudem die Datenqualität sichergestellt werden.

Bevor Datensätze mit Analyseverfahren untersucht werden können, ist es in den meisten Fällen erforderlich, dass die Daten vorverarbeitet und strukturiert werden. Die Prozessschritte können methodisch anhand des in Abbildung 2.1 dargestellten KDD-Prozesses durchgeführt werden. Das Vorgehen ist iterativ gestaltet und gliedert sich in fünf Schritte. Die einzelnen Schritte können beliebig oft wiederholt werden, um die Datenqualität in den einzelnen Schritten noch weiter zu steigern. [66]

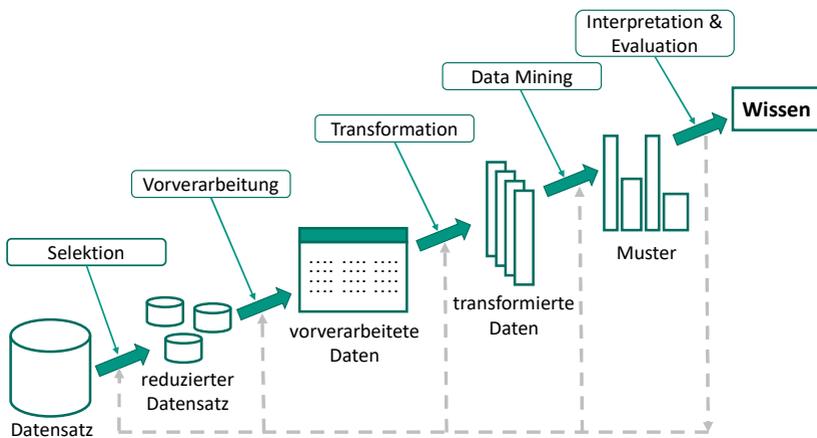


Abbildung 2.1: KDD-Prozess zur strukturierten Extraktion von Wissen aus Datenbeständen nach Fayyad [66]

Zu Beginn des Vorgehens stehen ein Datensatz sowie ein formuliertes Analysezziel. Anhand der Zieldefinition werden im ersten Schritt durch eine *Selektion* die für die Analyse relevante Daten und repräsentative Merkmale aus dem Datensatz ausgewählt. [66]

Im zweiten Schritt der *Vorverarbeitung* werden aus dem reduzierten Datensatz fehlerhafte Daten bereinigt, das Messrauschen gefiltert sowie gegebenenfalls weitere Metadaten zum Datensatz aggregiert. [66]

Auf dem vorverarbeiteten Datensatz wird im dritten Schritt eine *Transformation* durchgeführt. In dieser Transformation kommen mathematische oder statistische Methoden zum Einsatz. Beispielhaft genannt seien hier die Dimensionsreduktion sowie die Projektion. [66]

Das anschließende *Data Mining* stellt den zentralen Schritt des KDD-Prozesses dar. In diesem Schritt werden Algorithmen eingesetzt, welche Muster in den Daten erkennen können. Möglich ist der Einsatz konventioneller statistischer Methoden oder auch die Anwendung von Algorithmen des Maschinellen Lernens. [66]

Im letzten Schritt der *Interpretation & Evaluation* werden die Ergebnisse ausgewertet und interpretiert. Am Ende des Prozesses steht der Erkenntnisgewinn aus dem ursprünglichen Datensatz. [66]

In den folgenden Unterkapiteln werden verschiedenen Verfahren zum Data Mining vorgestellt, anhand derer mittels Algorithmen des Maschinellen Lernens Wissen aus Daten extrahiert werden kann.

2.1.2 Klassifikationsverfahren

Bei der Klassifikation werden durch eine Klassifizierung Objekte mit ähnlichen oder übereinstimmenden Merkmalen zu Klassen zusammengefasst [113]. Das Ziel ist es, auf Basis von erlernten Zusammenhängen neue Daten zuverlässig und automatisiert den korrekten Klassen zuzuweisen. Dabei wird zwischen drei Arten der Klassifizierung unterschieden. Die binäre Klassifizierung wird für Anwendungen verwendet, welche lediglich zwischen zwei Merkmalen differenzieren. Die Multi-Klassen-Klassifizierung wird bei mehr als zwei Zuständen eingesetzt. Bei der Multi-Label-Klassifizierung können einzelne Zustände in mehrere Klassen eingeordnet werden. [19]

Im Folgenden werden mit dem Decision Tree und dem Random Forest Verfahren zur Multi-Klassen-Klassifizierung betrachtet. Diese Algorithmen werden im weiteren Verlauf der Dissertation zur automatisierten Klassifikation des Fahrzustands der Straßenbahn eingesetzt.

2.1.2.1 Decision Tree

Entscheidungsbäume (engl. Decision Trees) sind geordnete und gerichtete Graphen, welche zur automatischen Klassifikation von Datenobjekten eingesetzt werden [167]. Entscheidungsbäume haben eine Struktur nach Abbildung 2.2.

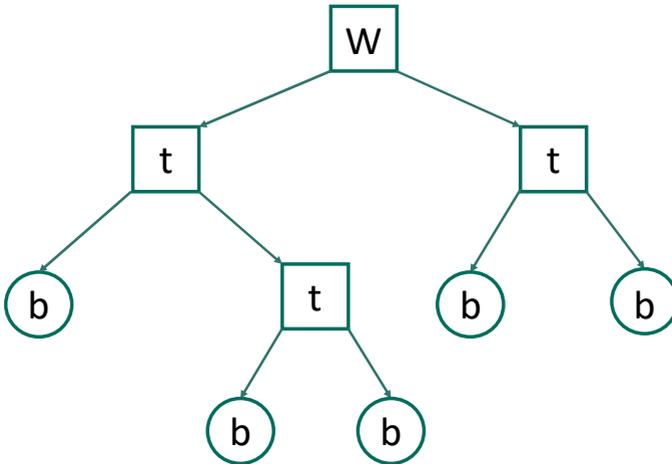


Abbildung 2.2: Aufbau eines Entscheidungsbaums nach [77]

Jeder Entscheidungsbaum hat eine Wurzel W , an welcher die Klassifikation beginnt. An jedem Knoten t werden Entscheidungen getroffen. Die Blätter b stellen die Endpunkte des Entscheidungsbaums dar. An diesen werden keine weiteren Entscheidungen mehr getroffen und der Zustand ist klassifiziert. [77]

Entscheidungsbäume zählen zu den nicht parametrischen Maschinellen Lernverfahren. Ein Baum wird rekursiv in einem Top-Down-Verfahren auf Basis des Trainingsdatensatzes aufgebaut. In jedem Schritt werden die Attribute gesucht, durch welche das Zielattribut am besten klassifiziert werden kann. [77] Das Ziel ist, den Informationsgewinn durch die Unterteilung in jedem Schritt zu maximieren. Maße hierfür entspringen der Informationstheorie und sind z. B. die Entropie oder der Gini-Index. [243]

Damit Entscheidungsbäume nicht zu groß werden und um Overfitting entgegenzuwirken, werden nach der Erstellung des Baums Knoten und ganze Teilstrukturen in einzelne Blätter umgewandelt. Diese Technik wird als Zurechtstutzen (engl.: pruning) bezeichnet. Dabei wird anhand einer Kostenfunktion

bewertet, ob das Stutzen von Knoten einen signifikanten Einfluss auf die Qualität der Klassifikation aufweist. Insofern die Auswirkung geringer als ein vordefinierter Schwellwert ist, wird der Knoten in ein Blatt umgewandelt. [243]

2.1.2.2 Random Forest

Trotz des Einsatzes von Regularisierungstechniken sind Entscheidungsbäume anfällig gegenüber Overfitting und haben dadurch Schwierigkeiten bei der Generalisierung [21]. Eine Weiterentwicklung der Entscheidungsbäume sind Entscheidungswälder (engl.: Random Forests). Diese sind den Ensemblemethoden zugeordnet. Bei diesen wird ein Kollektiv von Prädiktoren gebildet, welches nach dem Mehrheitsprinzip über die Klassifikation der Datenpunkte entscheidet. [27]

Entscheidungswälder sind Bagging-Verfahren, kurz für Bootstrap Aggregating. Die einzelnen Entscheidungsbäume werden jeweils mit einer zufällig ausgewählten sowie reduzierten Daten- und Merkmalsmenge trainiert (Bootstrapping) und nach ihrer Erstellung nicht weiter gestutzt. Die Klassifikation wird durch eine Mehrheitsentscheidung aller Entscheidungsbäume vorgenommen (Aggregating). [21]

Durch diese Anpassungen sind Entscheidungswälder wesentlich robuster gegenüber Overfitting als Entscheidungsbäume. Aufgrund der Vielzahl an Bäumen, welche zur Berechnung hinzugezogen werden, kann es jedoch zu Situationen kommen, in welchen der Random Forest nicht performant genug hinsichtlich der Rechenzeit ist. [21]

2.1.3 Künstliche Neuronale Netze

Künstliche Neuronale Netze (KNN) sind von biologischen neuronalen Netzen inspiriert und an eine Modellvorstellung des menschlichen Gehirns angelehnt. Ursprünglich wurden KNN in den Neurowissenschaften zur Erforschung des menschlichen Gehirns verwendet. [141] In den Ingenieurs- und Naturwis-

senschaften werden KNN mittlerweile genutzt, um Informationen zu verarbeiten und mathematische Funktionen zu approximieren [77]. Grundlage für KNN ist der *Universelle Approximationssatz* [97]. Nach diesem können vorwärtsgerichtete KNN mit einer einzigen versteckten Schicht bereits jede stetige Funktion zwischen Eingangs- und Ausgangsvariablen annähern. [228]

Das Kernelement von KNN sind künstliche Neuronen [77]. Abbildung 2.3 zeigt den grundlegenden Aufbau eines solchen künstlichen Neurons.

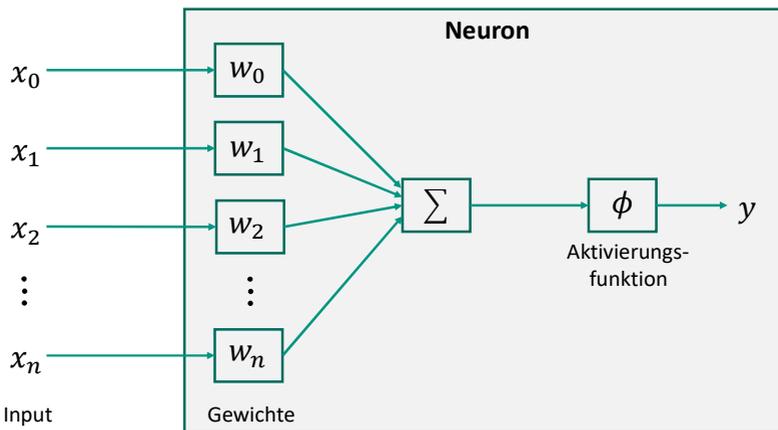


Abbildung 2.3: Aufbau eines künstlichen Neurons nach [77]

Ein Neuron erhält eine Vielzahl an Inputs x_0, \dots, x_n von mehreren Neuronen, welche alle miteinander verbunden sind. Diese Inputs werden mit Gewichten w_i multipliziert und anschließend aufsummiert. [158] Auf die Summe wird die Aktivierungsfunktion ϕ angewandt. Der Output y eines einzelnen Neurons ergibt sich nach Formel 2-1. [77]

$$y = \phi \left(\sum_{i=0}^n w_i \cdot x_i \right) \quad (2-1)$$

Als Aktivierungsfunktion ϕ können verschiedene Funktionen verwendet werden. Initial wurden Schwellwertfunktionen verwendet, welche sich jedoch als ungeeignet erwiesen haben, da die Gewichte der Neuronen mit einem Gradientenabstiegsverfahren trainiert werden und eine Schwellwertfunktion nicht stetig differenzierbar ist.

Häufig verwendet als Aktivierungsfunktion ϕ wird die Rectified Linear Unit (ReLU). Nach Formel 2-2 werden alle positiven Funktionsargumente auf sich selbst und alle negativen Argumente auf null abgebildet. [84]

$$ReLU(z) = \max(0, z) \quad (2-2)$$

ReLU ist stetig differenzierbar und hat den Vorteil, effizienter in der Berechnung als vergleichbare Aktivierungsfunktionen, wie beispielsweise Sigmoid- oder Tangenshyperbolicusfunktionen, zu sein [84].

Durch die Vernetzung mehrerer künstlicher Neuronen in mehreren Schichten entsteht ein Künstliches Neuronales Netz [84].

2.1.3.1 Multilayer-Perceptron

Die einfachste Form zur Realisierung von KNN sind sogenannte Perzeptren (engl.: Perceptrons). Diese besitzen lediglich eine Eingabe- und eine Ausgabeschicht. Wenn mehrere Schichten zwischen Eingabe- und Ausgabeschicht vorhanden sind, handelt es sich um ein mehrschichtiges Perzeptron (engl.: Multilayer Perceptron, MLP). Wenn mehr als zwei versteckte Schichten in einem Netz vorhanden sind, wird das Netz als tiefes Neuronales Netz bezeichnet (engl.: Deep Neural Network). Ein MLP ist meist vollvernetzt. Jedes Neuron einer Schicht ist mit jedem Neuron der nächsten Schicht vernetzt. Abbildung 2.4 zeigt die Struktur eines vollvernetzten MLP mit mehreren Inputs, mehreren versteckten Schichten und einem Output. [77]

Durch die Erhöhung der Schichten und der Anzahl der Neuronen können grundsätzlich höherdimensionale Funktionen angenähert werden. Dies führt jedoch nicht immer zu besseren Ergebnissen, da dies zum Teil Overfitting (vgl.

Kapitel 2.1.3.4) begünstigt und die Generalisierungsfähigkeiten der Neuronalen Netze einschränkt. [77]

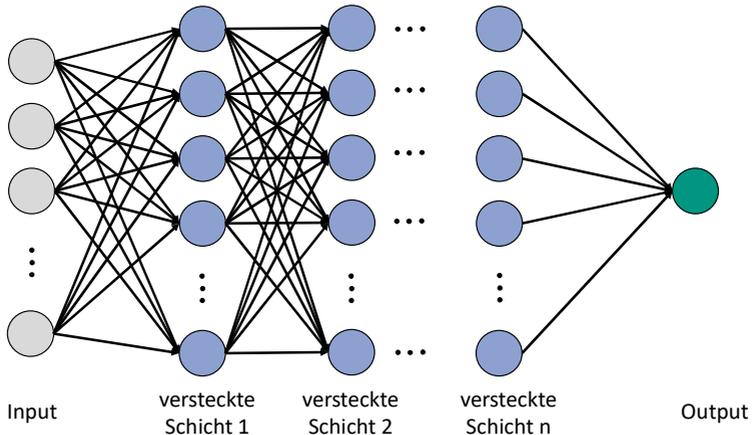


Abbildung 2.4: MLP mit mehreren versteckten Schichten und einem Output nach [77]

2.1.3.2 Convolutional Neural Network

Convolutional Neural Networks (CNN) sind eine Weiterentwicklung von Multilayer-Perceptrons. CNN wurden entworfen, um Daten zu verarbeiten, welche in Form von Arrays eingespeist werden [130]. Erfolge können CNN beim Einsatz in der Bild- und Spracherkennung verzeichnen [129]. Der schematische Aufbau eines Convolutional Neural Networks mit einer Faltungs-, einer Pooling- und einer vollvernetzten Schicht sowie dem Output ist in Abbildung 2.5 dargestellt.

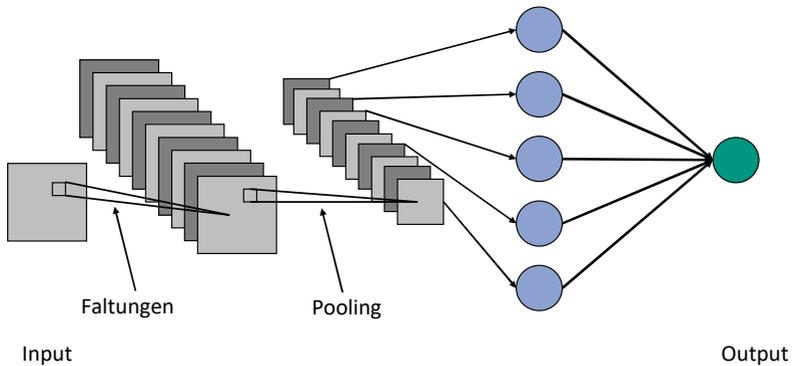


Abbildung 2.5: Schematischer Aufbau eines Convolutional Neural Networks nach [77]

Die ersten Schichten des Netzes bestehen aus Faltungs- und Poolingschichten. Die Faltungsschichten nehmen eine diskrete Faltung der Inputs vor, welche durch die Poolingschichten weiter aggregiert werden. Durch diese mathematischen Operationen wird bereits eine Datenregularisierung durchgeführt, wodurch im Allgemeinen die Generalisierungsfähigkeit der Neuronalen Netze verbessert wird. [77]

Die Ein- und Ausgaben der Konvolutionsschichten müssen dabei nicht wie beim MLP als eindimensionaler Vektor ausgeführt werden, sondern können auch eine Matrix oder ein Tensor höherer Dimension sein. Die Neuronen in den Konvolutionsschichten werden auf die Aktivierung hinsichtlich bestimmter Merkmale trainiert und agieren dabei als Filter, welcher schrittweise über den Input geschoben wird. Durch die Kombination mehrerer solcher Filter in Folgeschichten können höherdimensionale und anspruchsvolle Merkmale in den Daten erkannt werden. [77]

Mit dem anschließenden Pooling wird eine lokale Aggregation der Inputs durchgeführt. Wie bei der Faltung wird ein vordefinierter Bereich gefiltert, in dem entweder das Maximum dieses Bereichs (Maximum Pooling) oder der Durchschnitt des Bereichs (Average Pooling) aggregiert wird. [77]

In größeren Architekturen können mehrere Konvolutions- und Poolingschichten aufeinanderfolgen. Anschließend wird in der Regel durch den Einsatz von mindestens einer vollvernetzten Schicht die Ausgabe des Netzes generiert. [77]

CNN erfüllen die Kriterien der Translationsinvarianz. Bekannte Merkmale werden unabhängig von der Position im Array oder im Tensor zuverlässig erkannt. Von dieser Eigenschaft machen vor allem Methoden aus dem Maschinellen Sehen Gebrauch. [129]

2.1.3.3 Long-Short-Term Memory Networks

Long-Short-Term-Memory Netzwerke (LSTM) sind eine Form von Rekurrenten Neuronalen Netzen (RNN) [93]. Im Gegensatz zum MLP und zu CNN sind RNN nicht rein vorwärtsgerichtet und besitzen eine Rückkopplung. Dadurch können Informationen und bereits Gelerntes im Neuronalen Netz gespeichert werden. Aus diesem Grund eignen sich RNN zur Verarbeitung von sequentiellen Daten, z. B. Zeitreihen. [129]

LSTM sind eine spezialisierte Form von RNN, welche entwickelt wurden, um dem Problem der verschwindenden oder explosionsartig wachsenden Gradienten bei konventionellen RNN entgegenzutreten [93]. Aufgrund des sequentiellen Charakters der Inputdaten finden LSTM seither Anwendungen in der Sprach- und Texterkennung [129] oder auch in der Prädiktion der Einspeisung erneuerbarer Energien in das Stromnetz [36, 230].

Abbildung 2.6 zeigt den Aufbau einer Long-Short-Term-Memory-Netzwerk-Zelle. Diese besteht nicht rein aus künstlichen Neuronen, sondern aus verschiedenen Toren, welche miteinander interagieren, um den Zellzustand c_t und den Ausgabewert y_t zu berechnen.

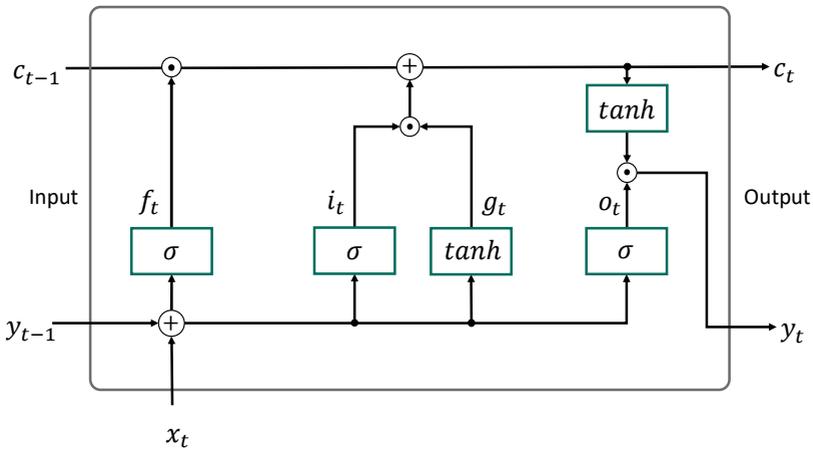


Abbildung 2.6: Schematischer Aufbau eines Long-Short-Term-Memory-Netzwerks nach [230]

Zu jedem Zeitpunkt t besitzen LSTM-Zellen einen Zellzustand c_t , welcher gespeichert und im folgenden Zeitschritt weiterverarbeitet wird. LSTM-Zellen verfügen zudem über verschiedene Tore. Diese Tore bestehen aus vollvernetzten Schichten und verarbeiten die Inputwerte x_t sowie die Ausgabewerte y_{t-1} des vorherigen Zeitschritts. Jedes dieser Tore besitzt eigene Gewichtungsmatrizen und Bias-Werte. Die Berechnungen der Tore werden durch sigmoide Aktivierungsfunktionen geleitet. [81]

Mit dem Vergesstor f_t (engl.: forget gate) wird gesteuert, in welchem Maße Werte in der Zelle verbleiben oder vergessen werden. Das Eingangstor i_t (engl.: input gate) bestimmt, mit welchem Gewicht ein neuer Wert in die Zelle einfließt. Das Ausgangstor o_t (engl.: output gate) steuert das Maß, mit welchem der Output der jetzigen Zelle zur Berechnung der nächsten Zelle verwendet wird. [81]

Zusätzlich zum Eingangstor werden durch den Ausgabewert g_t die Inputs x_t sowie y_{t-1} verarbeitet. Dies entspricht einer RNN-Zelle. Durch die Erweiterung der Zelle um die drei beschriebenen Tore können die wichtigsten Anteile

der Inputs langfristig gespeichert werden. Dies wird dann als LSTM-Zelle bezeichnet. [81]

Für den Zustand der Zelle c_t gilt demnach

$$c_t = (c_{t-1} \odot f_t) \oplus (i_t \odot g_t). \quad (2-3)$$

Die Ausgabe von LSTM-Zellen ist definiert als

$$y_t = o_t \odot \tanh(c_t). \quad (2-4)$$

2.1.3.4 Training Neuronaler Netze

Das Training Neuronaler Netze hat das Ziel, die optimalen Gewichte der einzelnen Neuronen zu ermitteln. Zum Training werden die Trainingsmerkmale in das Netz gespeist und die Ausgabe des Neuronalen Netzes mit dem Zielwert anhand einer vordefinierten Verlustfunktion bewertet. [33]

Bei überwachten Lernverfahren kann als Zielfunktion der Regression z. B. die mittlere quadratische oder die mittlere absolute Abweichung als Fehlermaß gewählt werden [81]. Zur Minimierung dieser Verlustfunktion werden Gradientenabstiegsverfahren angewendet. Durch Betrag und Richtung der Abweichung werden die Gewichte der Neuronen für die nächste Iteration angepasst. Dadurch wird eine inkrementelle Verbesserung des Modells für jedes Trainingsbeispiel erreicht. Dies wird solange durchgeführt, bis das Modell konvergiert. [33]

Bei tiefen Neuronalen Netzen kann die Verlustfunktion zunächst nur auf die Ausgabeschicht des Netzes angewandt werden, da nur dort der Vergleich zwischen der Ausgabe des Netzes und des Zielwerts möglich ist. Zur Durchführung des Gradientenabstiegsverfahrens muss der Fehler in den vorangegangenen Schichten ermittelt werden. Dies wird durch die Rückwärtspropagierung (engl.: Backpropagation) des Fehlergradienten durch alle Schichten auf Basis der Kettenregel erreicht [176, 246]. Dadurch ist eine Anpassung der Gewichte mittels des Gradientenabstiegsverfahrens möglich. [33]

Im ersten Schritt des Trainings werden sämtliche Gewichte des Neuronalen Netzes mit zufälligen Werten außer Null initialisiert. Anschließend werden die Datenpunkte durch das Neuronale Netz vorwärts propagiert und die Ausgaben aller Neuronen gespeichert. Darauffolgend wird, beginnend mit der Ausgangsschicht, der Fehlergradient auf Basis einer vordefinierten Fehlerfunktion für alle Neuronen berechnet. [33]

Abschließend wird ein Gradientenabstieg in Richtung des Minimums der Fehlerfunktion durchgeführt, mit dem die Neuronengewichte angepasst werden. Hierfür wird eine Lernrate η definiert, die festlegt, wie stark die Änderung der Neuronengewichte zwischen zwei Trainingsdurchläufen sein darf. Stand der Technik sind adaptive Gradientenabstiegsverfahren wie der Adam-Algorithmus, welche die Lernrate η dynamisch anpassen [118]. Durch die intelligente Schrittweitenanpassung wird das Training beschleunigt und eine zuverlässige Konvergenz sichergestellt. [33, 118]

Hyperparametertuning

Neben der Anpassung der internen Modellparameter wird das Trainingsergebnis von den gewählten Hyperparametern beeinflusst [77].

Definition 2.1: Hyperparameter

Hyperparameter sind Parameter für das Training Maschinellem Lernverfahren, mit welchen Geschwindigkeit und Qualität des Lernprozesses beeinflusst werden. Hyperparameter werden vor dem Start des Trainings festgelegt und verändern sich währenddessen nicht. [77]

Beispiele für Hyperparameter sind die Anzahl der Epochen, die Batch-Size sowie die oben aufgezeigte Lernrate η . Weitere modellspezifische Hyperparameter sind die Anzahl der Schichten des Neuronalen Netzes sowie die Zahl der Neuronen der jeweiligen Schicht. [77]

Definition 2.2: Epoche

Die Anzahl der Epochen legt fest, wie oft der Lernalgorithmus den gesamten Trainingsdatensatz durcharbeitet. In einer Epoche wird der Trainingsdatensatz einmal durchlaufen. Somit hat jeder Datenpunkt in einer Epoche die Möglichkeit, die internen Modellparameter des Neuronalen Netzes zu beeinflussen. [77]

Definition 2.3: Batch-Size

Die Batch-Size legt fest, nach welcher Anzahl an Stichproben die internen Modellparameter aktualisiert werden [77].

Bei einer Batch-Size von eins wird nach jeder Stichprobe das Gradientenabstiegsverfahren durchlaufen. Grundsätzlich wird die Batch-Size so groß wie möglich gewählt, da die Berechnung des Fehlergradienten rechenzeitintensiv ist. Die Größe der Batch-Size ist durch den verfügbaren Speicher limitiert. [77]

Zum Training Neuronaler Netze wird der gesamte Datensatz in einen Trainings- und Testdatensatz unterteilt. Meist umfasst der Trainingsdatensatz zwischen 60 und 80 Prozent des gesamten Datensatzes. Testdaten werden nicht zur Anpassung der internen Modellparameter während des Trainingsprozesses genutzt. Durch das Training mit dem Trainingsdatensatz werden die internen Modellparameter angepasst. Zur Untersuchung der Generalisierungsfähigkeiten wird das trainierte Modell auf dem Testdatensatz auf den Prädiktionsfehler ausgewertet. [77] Der Zusammenhang zwischen dem Prädiktionsfehler und der Modellgröße ist in Abbildung 2.7 dargestellt [192]. Es zeigt sich, dass ein größeres Modell durch mehr Schichten und Neuronen nicht grundsätzlich zu einer besseren Generalisierung, sondern zu Overfitting, einer Überanpassung an den Trainingsdatensatz, führt [192]. Häufig erlernt das Modell das Rauschen oder weitere irrelevante Informationen auf den Trainingsdaten, wodurch eine Verallgemeinerung auf den Testdatensatz schlechter wird [192].

Bei einem zu kleinen Modell für die Problemstellung kann die Zielfunktion

nicht genau genug approximiert werden, was in einem Underfitting (dt.: Unteranpassung) resultiert [192].

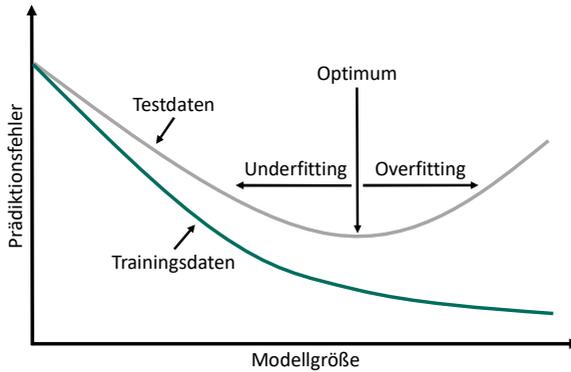


Abbildung 2.7: Zusammenhang zwischen Modellgröße und Prädiktionsfehler für Trainings- und Testdatensatz nach [192]

Zur Ermittlung des Optimums zwischen Overfitting und Underfitting ist ein Tuning der Hyperparameter notwendig. Traditionell wird dieses Tuning mit einer Grid Search durchgeführt, in welcher ein Versuchsraum aus den Hyperparametern aufgespannt und vollfaktoriell durchlaufen wird. Weitere Möglichkeiten sind eine zufällige Suche innerhalb eines vordefinierten Suchraums sowie das Tuning mittels Metaheuristiken mit evolutionären oder naturinspirierten Algorithmen. [248]

Regularisierungstechniken

Regularisierungstechniken haben das Ziel, Overfitting entgegenzuwirken. Mit der Regularisierung werden weitere Hyperparameter eingeführt. [77]

Durch *Dropout* werden einzelne Neuronen einer Schicht während einer Epoche mit einer vordefinierten Wahrscheinlichkeit $p \in [0, 1]$ deaktiviert. Ledig-

lich die Gewichte der noch aktiven Neuronen werden ausgewertet und angepasst. Dadurch reduziert sich die Modellgröße und es kann Overfitting entgegengewirkt werden. Die Deaktivierung von Neuronen kann nur in der Eingabeschicht sowie den Zwischenschichten und nicht der Ausgabeschicht durchgeführt werden. [77]

Mit *Early Stopping* wird das Training frühzeitig beendet, insofern sich nach einer vordefinierten Anzahl an Episoden der Prädiktionsfehler auf dem Testdatensatz nicht verbessert. In diesem Fall wird das Training abgebrochen, um ein Overfitting auf die Trainingsdaten zu vermeiden. [77]

2.1.4 Deep Reinforcement Learning

Reinforcement Learning differenziert sich von anderen Ansätzen des Maschinellen Lernens dadurch, dass nicht auf Basis eines bestehenden Datensatzes gelernt wird, sondern das fundamentale Konzept des menschlichen Lernens durch Interaktionen mit der Umwelt zugrunde liegt. [199]

Das grundlegende Konzept von Reinforcement Learning ist in Abbildung 2.8 dargestellt und basiert auf einem Markov-Entscheidungsprozess (engl.: Markov Decision Process, MDP) [199]. Dieser hat die Eigenschaft, dass für stochastische zeitdiskrete Zustandsketten die bedingte Wahrscheinlichkeit eines Zustandsübergangs lediglich vom aktuellen Zustand abhängt und nicht von weiter zurückliegenden [138].

Beim Reinforcement Learning interagiert ein Agent durch Aktionen mit seiner Umgebung mit dem Ziel belohnungsmaximierendes Verhalten zu erlernen. Zu jedem diskreten Zeitschritt t wählt der Agent eine Aktion $a \in A$ mit Bezug auf seine Policy aus. Dies resultiert in einem Übergang des Zustands $s \rightarrow s'$ der Umgebung. Darauf folgend erhält der Agent einen Reward r von der Umgebung. Dieser Reward wird von einer vordefinierten Rewardfunktion berechnet und gibt dem Agenten eine Rückmeldung, wie gut die zuvor gewählte Aktion in Bezug auf den aktuellen Zustand der Umgebung ist. Der kumulative Reward über eine gesamte Trajektorie wird als Return R_t bezeichnet und ist

nach Formel 2-5 als die Summe über einen unendlichen Zeithorizont definiert. Der Discount-Faktor $\gamma \in [0, 1)$ wiegt sofortige gegenüber zukünftige Rewards auf. Für γ gegen 1 legt der Agent großen Wert auf zukünftige Rewards. Falls γ gegen 0 geht, fokussiert sich der Agent auf sofortige Rewards. [199]

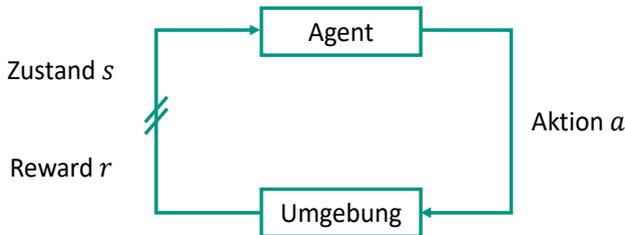


Abbildung 2.8: Interaktion von Agent und Umgebung im Reinforcement Learning nach [199]

$$R_t = \sum_{i=t}^T \gamma^{i-t} \cdot r(s_i, a_i) \quad (2-5)$$

Bei Reinforcement Learning Problemen soll der Agent eine optimale Policy π erlernen, welche den Erwartungswert des Returns $J(\pi)$ nach Formel 2-6 in jeder Trainingsepisode maximiert. [10]

$$J(\pi) = \mathbb{E}_{\pi}[R_t] \quad (2-6)$$

Für die optimale Policy π^{ϕ} mit den Parametern ϕ gilt demnach nach Formel 2-7 [10]

$$\pi^{\phi} = \arg \max_{\pi} J(\pi). \quad (2-7)$$

Die optimale Policy π^{ϕ} wird durch das Lernen des Agenten aus Interaktionen mit der Umwelt ermittelt. Der Agent sammelt Erfahrungen, indem er Aktionen in der Umgebung ausführt und die daraus resultierenden Belohnungen analysiert. [10]

Ein weiteres grundlegendes Konzept im Reinforcement Learning sind Value-Funktionen. Eine Value-Funktion $V^\pi(s)$ berechnet nach Gleichung 2-8 den erwarteten Return, wenn der Agent in einem Zustand s_0 startet und dabei eine Policy π ausführt. [10]

$$V^\pi(s) = \mathbb{E}_\pi[R_t \mid s_0 = s] \quad (2-8)$$

Die optimale Value-Funktion $V^\phi(s)$ ermittelt nach Formel 2-9 den Erwartungswert des Returns, wenn im Zustand s_0 gestartet wird und stets nach einer optimalen Policy gehandelt wird. [10]

$$V^\phi(s) = \max_\pi \mathbb{E}_\pi[R_t \mid s_0 = s] \quad (2-9)$$

Zusätzlich zur Value-Funktion existiert die Action-Value-Funktion $Q^\pi(s, a)$. Diese Funktion berechnet nach Gleichung 2-10 den erwarteten Return, wenn im Zustand s_0 gestartet wird, die Aktion a_0 ausgeführt wird und anschließend nach einer Policy π gehandelt wird. [10]

$$Q^\pi(s, a) = \mathbb{E}_\pi[R_t \mid s_0 = s, a_0 = a] \quad (2-10)$$

Die optimale Action-Value-Funktion $Q^\phi(s, a)$ ist dementsprechend nach Formel 2-11 gegeben, wenn im Zustand s_0 eine Aktion a_0 ausgeführt wird und stets eine optimale Policy π ausgeführt wird. [10]

$$Q^\phi(s, a) = \max_\pi \mathbb{E}_\pi[R_t \mid s_0 = s, a_0 = a] \quad (2-11)$$

Die Action-Value-Funktion kann entweder durch eine mathematische Funktion oder auch eine Look-Up-Tabelle definiert werden, welche die Zustands-Aktions-Paare beinhaltet. [10]

Die Berechnung der optimalen Value- und Action-Value-Funktion kann in kleinen Aktions- und Zustandsräumen trivial sein. In großen Zustands- und Aktionsräumen kann die Erstellung einer Funktion zu herausfordernd und der Einsatz von Look-Up-Tabellen durch den verfügbaren Speicher limitiert sein. Zur

Lösung dieses Problems können tiefe Neuronale Netze als Funktionsapproximatoren eingesetzt werden. Zusätzlich ermöglicht der Einsatz tiefer Neuro-naler Netze die Umsetzung kontinuierlicher Aktions- und Zustandsräume. Wenn tiefe Neuronale Netze zur Approximation der Value- und Action-Value-Funktion eingesetzt werden, wird dies als Deep Reinforcement Learning (Deep-RL) bezeichnet. [10]

2.1.4.1 Reinforcement Learning Algorithmen

Es gibt eine Vielzahl an Algorithmen, welche in Reinforcement Learning An-wendungen zum Einsatz kommen [53]. Abbildung 2.9 zeigt eine Unterteilung der Algorithmen in ihre Klassen.

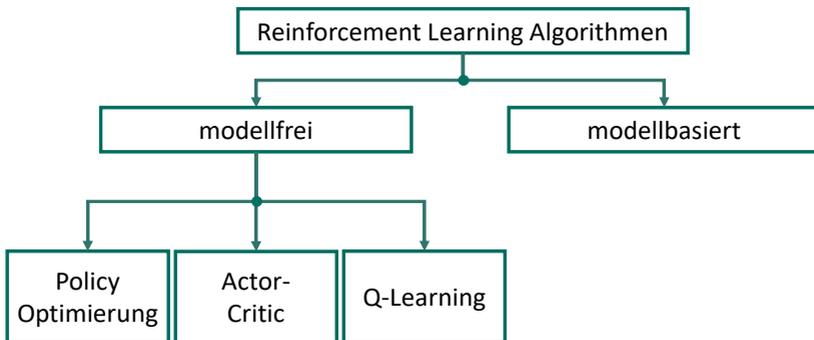


Abbildung 2.9: Unterteilung von Reinforcement Learning Algorithmen nach [53]

Zunächst werden die Algorithmen in modellbasierte und modellfreie Algorithmen unterteilt. Bei modellbasierten Ansätzen sind das gesamte Modell der Umgebung sowie eine Funktion zur Prädiktion der Zustandsübergänge und der Rewards bekannt. In modellfreien Algorithmen erlernt der Agent diese Funktion durch Interaktion mit der Umgebung. Modellfreie Ansätze finden nach aktuellem Stand der Technik ein breiteres Anwendungsspektrum, da es sich häufig als herausfordernd erweist, ein gesamtheitliches Modell aller Zu-

standsübergänge und Rewards zu erzeugen. Des Weiteren besteht bei modellbasierten Ansätzen die Gefahr, dass der Agent in der simulierten Umgebung sehr gute Ergebnisse erzielt, aufgrund von Modellierungs-ungenauigkeiten in der echten Welt jedoch keine optimalen Lösungen generiert.

Modellfreie Algorithmen lassen sich weiter in drei Klassen aufteilen. Algorithmen der Policy Optimierung haben das Ziel, die Value-Funktion nach Gleichung 2-8 zu optimieren. Beim Q-Learning wird versucht, den Erwartungswert der Action-Value-Funktion nach Formel 2-10 zu maximieren. Actor-Critic-Methoden stellen eine Kombination aus Policy-Optimierung und Q-Learning dar. Ein Actor erlernt eine Policy auf Basis der Value-Funktion und ein Critic erlernt die Action-Value-Funktion. Diese Kombination aus beiden Verfahren ermöglicht es, kontinuierliche Aktions- und Zustandsräume zu realisieren. Des Weiteren ist der Trainingsprozess stabiler und konvergiert schneller. [53]

Im Rahmen der Forschungsarbeit werden daher Actor-Critic-Methoden angewandt.

2.1.4.2 Twin Delayed Deep Deterministic Policy Gradient

Ein Algorithmus aus der Gruppe der Actor-Critic-Algorithmen ist *Twin Delayed Deep Deterministic Policy Gradient* (TD3). Dieser Algorithmus wurde erstmals 2018 vorgestellt [78] und findet seither vermehrt Anwendung in der Robotik und weiteren Bereichen der Steuerung und Regelung in kontinuierlichen Aktions- und Zustandsräumen [41, 117]. Die Grundstruktur des Algorithmus ist in Abbildung 2.10 dargestellt.

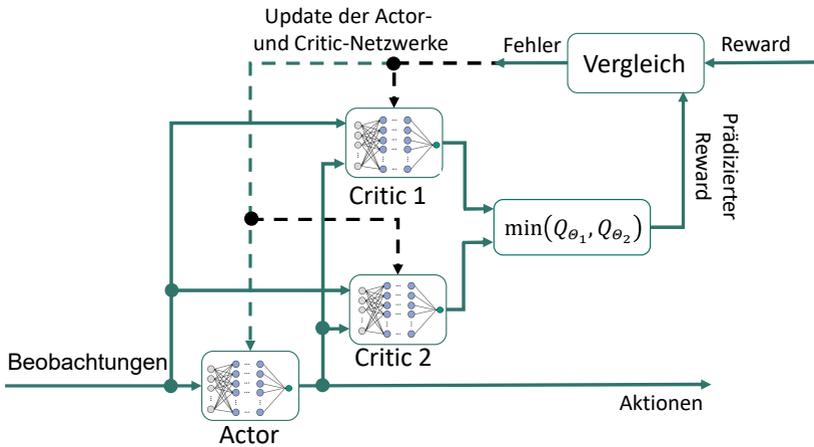


Abbildung 2.10: Zusammenspiel von Actor- und Critic-Netzwerken beim TD3-Algorithmus nach [86]

Auf Basis der Beobachtungen aus der Umgebung wählt der Actor eine Aktion anhand seiner aktuellen Policy aus. Die Critic-Netzwerke prädizieren mit ihrer Action-Value-Funktion den Reward zur vom Actor ausgewählten Aktion. Dieser prädizierte Wert wird mit dem tatsächlichen Reward der Umgebung verglichen. Aus der Abweichung zwischen dem prädizierten und dem tatsächlichen Reward werden die Actor- und Critic-Netzwerke angepasst. Dadurch werden die Prädiktion der Critic-Netzwerke und die Policy des Actor-Netzwerks verbessert. [78]

TD3 ist eine Weiterentwicklung des 2015 veröffentlichten *Deep Deterministic Policy Gradient*-Algorithmus (DDPG) [135]. Actor-Critic-Methoden haben grundsätzlich das Problem eines Überschätzungs-Bias (engl.: overestimation bias). Deswegen überschätzt der Agent einzelne Zustände und verzerrt die Policy hinsichtlich dieser Zustände gegenüber anderen, welche zu wesentlich besseren Rewards führen würden. Der Einsatz von tiefen Neuronalen Netzen verstärkt dieses Problem noch weiter, da diese ebenfalls nur Approximatio-

nen der Policy sowie der Action-Value-Funktion sind. Aus diesem Grund verwendet TD3 im Gegensatz zu DDPG ein zweites Critic-Netzwerk nach Abbildung 2.10. [78] Dies ist inspiriert vom Double-Q-Learning-Algorithmus, bei welchem ebenfalls zwei Critic-Netzwerke unabhängig voneinander mit den Parametern θ_1 und θ_2 trainiert werden [229]. Von beiden Critic-Netzwerken wird in jedem Zeitschritt das prädizierte Minimum verwendet, wodurch der Überschätzungs-Bias reduziert wird [229]. Zur weiteren Stabilisierung des Trainings wird die Policy bei TD3 nicht nach jedem Schritt aktualisiert. Dadurch wird die Wahrscheinlichkeit reduziert, dass eine Aktualisierung der Policy durchgeführt wird, obwohl in einem Zeitschritt die Critic-Netzwerke nicht angepasst wurden. Diese verringerten Aktualisierungen der Policy nutzen dementsprechend qualitativ hochwertigere Schätzungen des Rewards der Critic-Netzwerke. Daraus resultieren grundsätzlich hochqualitativere Anpassungen des Actor-Netzwerks. [78]

Der Pseudo-Code von TD3 ist in Algorithmus 1 beschrieben [78]. Vor dem ersten Trainingsdurchlauf werden die Actor- und Critic-Netzwerke mit zufälligen Startparametern initialisiert. Die Startparameter werden ebenfalls für die Target-Netzwerke des Actor und der beiden Critics genutzt. Diese Target-Netzwerke dienen der weiteren Stabilisierung des Trainings. Zusätzlich wird der Replay-Speicher \mathfrak{B} initialisiert, welcher die Zustandsübergänge speichert. [78]

Eine Iteration umfasst die Auswahl einer Aktion sowie die Beobachtung des Rewards und des darauffolgenden Zustands. Dieser Tupel wird im Replay-Speicher abgespeichert. Die Aktion wird mit einem Rauschen überlagert, wodurch der Agent zur Exploration neuer Zustände gezwungen wird. Anschließend wird ein Mini-Batch aus dem gesamten Replay-Speicher geladen. Anhand dessen werden mit den Target-Netzwerken die Zielwerte des Mini-Batches berechnet. Der daraus errechnete Fehler wird genutzt, um die Parameter der Critic-Netzwerke anzupassen. Durch das Lernen anhand zurückliegender Beispiele, welche nicht zwingend mit der jetzigen Policy übereinstimmen, zählt TD3 zu den Off-Policy-Algorithmen. [78]

Wenn der Zeitschritt identisch zur Schrittweite der Aktualisierung des Policy-

Netzwerks ist, wird dieses ebenfalls angepasst. Des Weiteren werden die Target-Netzwerke aktualisiert. Die Parameter der Target-Netzwerke werden durch den Soft-Update-Faktor weniger stark angepasst. [78]

Algorithmus 1 TD3-Algorithmus nach [78]

Zufällige Initialisierung der Critic-Netzwerke Q_{θ_1} und Q_{θ_2} sowie des Actor-Netzwerks π^φ mit den Parametern $\theta_1, \theta_2, \varphi$

Initialisierung der Target-Netzwerke $\theta'_1 \leftarrow \theta_1, \theta'_2 \leftarrow \theta_2, \varphi' \leftarrow \varphi$

Initialisierung des Replay-Speichers \mathfrak{B}

for $t = 1$ **bis** T **führe aus**

- Wähle eine Aktion mit Explorationsrauschen aus $a \sim \pi_\varphi(s) + \varepsilon$, $\varepsilon \sim \mathcal{N}(0, \sigma)$ und beobachte den Reward r sowie den neuen Zustand s'
- Speichere den Übergangstupel (s, a, r, s') in \mathfrak{B}
- Lade einen Mini-Batch von N Übergangstupeln (s, a, r, s') aus \mathfrak{B}
- Berechne der Target-Aktion und der Target-Werte aus Tupeln des Mini-Batches
- Update der Critic-Netzwerke mit den Parametern θ_1, θ_2

if $t \bmod \text{Policy-Verzögerung}$ **dann**

- Aktualisiere das Policy-Netzwerk mit den Parametern φ
- Aktualisiere die Target-Netzwerke mit den Parametern $\theta'_1, \theta'_2, \varphi'$ mit dem Soft-Update-Faktor τ ($\tau \ll 1$)
- $\theta'_i \leftarrow \tau \cdot \theta_i + (1 - \tau) \cdot \theta'_i$
- $\varphi' \leftarrow \tau \cdot \varphi + (1 - \tau) \cdot \varphi'$

end if

end for

2.2 Dynamische Programmierung

Die dynamische Programmierung (engl.: Dynamic Programming, DP) nach Bellmann ist ein Optimalsteuerungsproblem, welches bei der Einhaltung der

methodischen Prinzipien zu einer garantierten globalen Optimalität der Lösung führt. Das Verfahren zeichnet sich durch die geringstmögliche Komplexität bei gleichzeitiger Garantie des globalen Optimums aus. [17]

Die dynamische Programmierung findet in unterschiedlichen Disziplinen wie der Regelungstechnik, der Entscheidungstheorie oder dem Operations Research Einsatz. [17]

Der dynamischen Programmierung zugrunde liegt das Bellmansche Optimalitätsprinzip. Dieses besagt, dass eine optimale Entscheidungsfolge stets aus optimalen Teillösungen bestehen muss. Bei der dynamischen Programmierung wird das Optimierungsproblem daher als mehrstufiger Entscheidungsprozess modelliert. Dabei können beliebige Randbedingungen durch Zustands- und Steuerbeschränkungen leicht berücksichtigt werden. Die Lösung des Gesamtproblems kann ohne Rekursionen aus den Teillösungen zusammengesetzt werden. [16]

Das Hauptproblem der dynamischen Programmierung ist der hohe Rechenaufwand, welcher benötigt wird, um sämtliche Teillösungen zu erzeugen, anhand derer die Optimallösung identifiziert wird. [17]

2.3 Fahrwiderstände

Bei Betrachtung eines einfachen mechanischen Modells ergibt sich für das Kräftegleichgewicht im Schwerpunkt der Zusammenhang nach Formel 2-12

$$(F_x - F_{Br}) - F_W = F_a. \quad (2-12)$$

Dabei ist F_x die Zugkraft des Fahrzeugs, F_{Br} die Bremskraft, F_W die Gesamtfahrwiderstandskraft und F_a die Trägheitskraft. Der Gesamtfahrwiderstand F_W setzt sich nach Gleichung 2-13 aus dem Anfahrwiderstand F_A , dem Streckenwiderstand F_S sowie dem Laufwiderstand F_L zusammen. [245]

$$F_W = F_A + F_S + F_L \quad (2-13)$$

Der Anfahrwiderstand F_A wirkt beim Anfahren entgegen der Fahrtrichtung. Der Laufwiderstand F_L ist konstruktiv bedingt und setzt sich im Wesentlichen aus dem Rollwiderstand F_{LR} , dem Reibungswiderstand F_{LW} sowie dem Luftwiderstand F_{LA} zusammen. Die Anteile des Laufwiderstands lassen sich in nicht-geschwindigkeitsabhängige, geschwindigkeitsabhängige und vom Quadrat der Geschwindigkeit abhängige Anteile unterteilen. Mathematisch wird der Laufwiderstand durch ein Polynom nach Gleichung 2-14 berechnet. Die Koeffizienten c_0 , c_1 und c_2 werden durch Messfahrten und Ausrollversuche empirisch bestimmt. c_0 repräsentiert den Anteil des Rollwiderstands. Durch c_1 wird der Reibungswiderstand modelliert und c_2 stellt den Luftwiderstand dar. [245]

$$F_L = c_0 + c_1 \cdot v + c_2 \cdot v^2 \quad (2-14)$$

Des Weiteren werden die Fahrwiderstände maßgeblich durch die Infrastruktur beeinflusst. Diese von der Streckenführung abhängigen Fahrwiderstände werden unter dem Streckenwiderstand F_S zusammengefasst. Die Bestandteile sind der Steigungswiderstand F_{SG} , der Bogenwiderstand F_{SB} und der Tunnelwiderstand F_{ST} . Aufgrund des Aufzeichnungszeitraums der Daten kommt der Tunnelwiderstand in dieser Forschungsarbeit nicht zu tragen. Der Karlsruher Stadtbahntunnel wurde erst im Dezember 2021 eröffnet und darüber hinaus gibt es im Karlsruher Straßenbahnnetz keine Tunnel. Der Steigungswiderstand F_{SG} nach Formel 2-15 ist abhängig von der Fahrzeugmasse m_{Fzg} , der Erdbeschleunigung g sowie dem Steigungswinkel α . [245]

$$F_{SG} = m_{Fzg} \cdot g \cdot \sin \alpha \quad (2-15)$$

Der Einfluss des Steigungswiderstands im Vergleich zum Laufwiderstand über der Fahrzeuggeschwindigkeit ist in Abbildung 2.11 dargestellt. Der Laufwiderstand wurde durch Ausrollversuche nach Springmann [194] in Abhängigkeit der Geschwindigkeit ermittelt. Dieser ist als blaue Kurve aufgetragen und ba-

siert auf einer Fahrt in der Ebene ohne Beschleunigung. Die orangenen Kurven zeigen den Effekt der Variationen der Steigung auf den gesamten Fahrwiderstand. Selbst geringe Steigungen von wenigen Promille resultieren durch die hohe Fahrzeugmasse in einer nennenswerten Erhöhung des Fahrwiderstands.

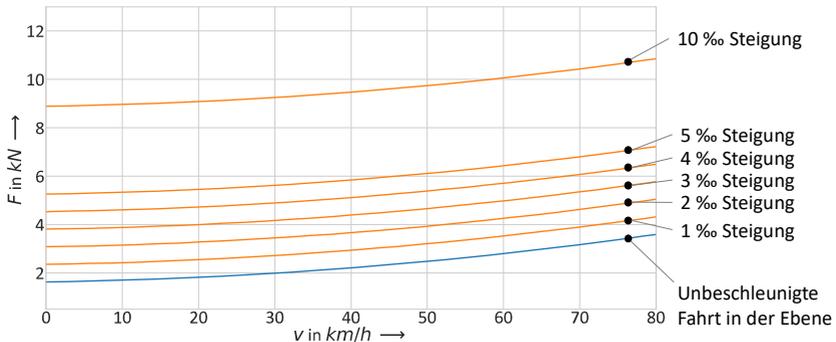


Abbildung 2.11: Laufwiderstand auf Basis von Ausrollversuchen nach Springmann [194] mit zusätzlicher Variation des Fahrwiderstands. Darstellung nach [104]

Straßenbahnen durchfahren während des täglichen Betriebs enge Bogenradien. Für Kurvenfahrten mit Radien kleiner 300 m gilt im Straßenbahnbereich nach Ihme [104] für den Bogenwiderstand die Gleichung 2-16

$$F_{SB} = m_{FzG} \cdot g \cdot \frac{0,158 \cdot a_R + 0,033 \cdot s_R}{R} \quad (2-16)$$

Der Radsatzabstand a_R sowie der Laufkreisabstand s_R sind konstruktive Parameter der Bahnen. Der Bogenradius R ist durch die Streckenführung vorgegeben. In dieser Dissertation wird ein Niederflur Elektrotriebwagen 2012 (NET 2012) im Karlsruher Straßenbahnnetz betrachtet (vgl. Tabelle 4.1). Aus technischen Zeichnungen des NET 2012 ergeben sich für $a_R = 1,9 \text{ m}$ und für $s_R = 1,49 \text{ m}$ [131].

In der Karlsruher Innenstadt treten Bogenradien ab 24 m auf. Zur Vergleichbarkeit von Bogenwiderstand und Steigungswiderstand werden die Formeln 2-15 und 2-16 gleichgesetzt, um eine äquivalente Steigung für Bogenradien zu berechnen [131]. Dieser Zusammenhang ist in Abbildung 2.12 dargestellt. Ein Bogenradius von 24 m entspricht damit einer äquivalenten Steigung von mehr als 14 ‰. Bogenradien treten zwar örtlich begrenzter als Steigungen auf, sind jedoch bezüglich der Auswirkung auf den Fahrwiderstand nicht zu vernachlässigen.

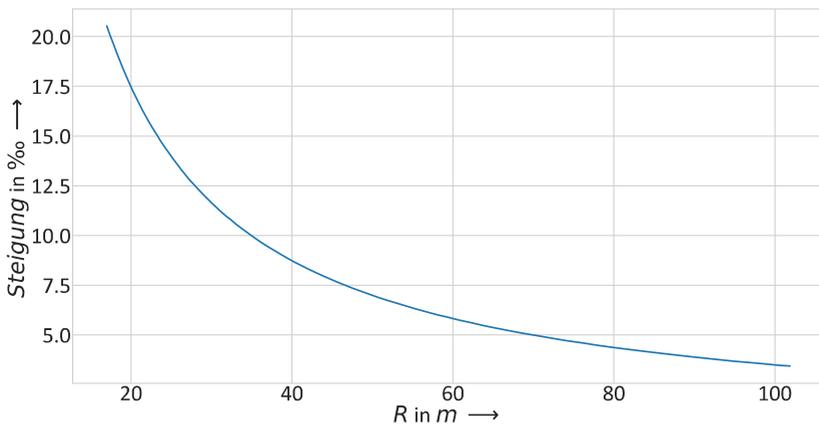


Abbildung 2.12: Äquivalente Steigung als Funktion des Bogenradius nach [131]

3 Problemstellung, Bewertung, Zielsetzung und Vorgehensweise

In diesem Kapitel wird zunächst die Problemstellung auf Basis des Stands der Technik und der Wissenschaft sowie der Grundlagen konkretisiert. Anschließend werden anhand von Bewertungskriterien verschiedene Lösungsansätze zur Berechnung energieeffizienter und pünktlicher Fahrprofile miteinander verglichen und ein Verfahren ausgewählt. Für dieses Verfahren wird die Zielsetzung der Dissertation anhand von Forschungshypothesen definiert. Aus den Forschungshypothesen werden anschließend der Lösungsansatz und die Vorgehensweise abgeleitet, mit welchem die Zielsetzung erreicht werden soll.

3.1 Problemstellung

Zunächst werden Strategien zum energieeffizienten und pünktlichen Fahren vorgestellt. Darauffolgend wird ein Überblick über Algorithmen zur Berechnung energiesparender und pünktlicher Fahrtrajektorien gegeben und die Herausforderungen abgeleitet.

Energieeffizientes und pünktliches Fahren

Schienenfahrzeuge haben infrastrukturbedingt lediglich einen Freiheitsgrad zur Wahl der Geschwindigkeit. Diese wird über die Zugkraftvorgabe des Fahrers eingestellt. Bei Schienenfahrzeugen kann die Energieeffizienz durch die Anpassung der Fahrtrajektorie erhöht werden. In Bahnsystemen mit abgetrenntem Bahnkörper werden durch Anpassung der Fahrtrajektorie Energieeinsparungspotentiale elektrischer Schienenfahrzeuge auf 17 bis 22 % beziffert [164, 180].

Zur Umsetzung einer energiesparenden Fahrweise muss die zur Verfügung stehende Fahrzeitreserve im Fahrplan ausgenutzt werden. Der energieeffizienteste Zustand des Schienenfahrzeugs während der Fahrt ist das sogenannte Coasting, das Ausrollen des Fahrzeugs. Die Traktionsleistung beim Coasting ist Null. Weitere Zustände sind die Beschleunigung, die Verzögerung und die Beharrungsfahrt (Cruising). Beim Cruising ist die resultierende Beschleunigung Null und die Traktionsleistung gering, da nur die Lauf- und Streckenwiderstände überwunden werden müssen. [180]

Abbildung 3.1 zeigt im Vergleich zwei Geschwindigkeitstrajektorien eines Schienenfahrzeugs. Beide Fahrprofile starten mit der maximal möglichen Beschleunigung und verharren anschließend für eine kurze Zeit auf der Maximalgeschwindigkeit. Das grüne Fahrprofil beginnt frühzeitig mit dem Ausrollvorgang, während das graue Fahrprofil die Maximalgeschwindigkeit über einen längeren Zeitraum hält und früher den Bremsvorgang mit maximaler Verzögerungsfähigkeit einleitet. Bei einer gegebenen Fahrzeitreserve ist das grüne Fahrprofil die energieeffizienteste und das graue Fahrprofil die zeitoptimale Fahrt. [184]

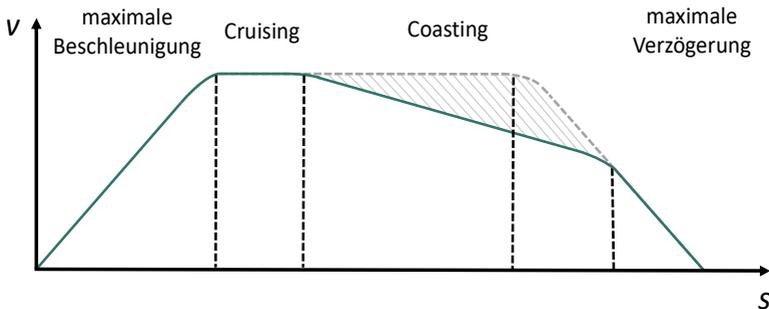


Abbildung 3.1: Energiesparende Fahrweise mit Coasting- und Cruising-Anteilen nach [184]

Die Fahrzeitreserve ist während des täglichen Betriebs aufgrund von variablen Passagierströmen, und im Falle der Straßenbahn durch zusätzliche Interaktionen mit dem Individualverkehr, keine konstante Größe. Nach Abbildung 3.2 gibt es dennoch für jede beliebige Fahrzeitreserve ein Fahrprofil mit höchster Energieeffizienz. Durch diesen Zusammenhang bildet sich eine Paretofront aus. Jeder Punkt auf der Paretokurve ist paretooptimal, wodurch es nicht möglich ist, eine Zieleigenschaft zu verbessern, ohne eine andere zu verschlechtern. Fahrprofile, die nicht auf der Paretokurve liegen, können hinsichtlich der Pünktlichkeit oder der Energieeffizienz optimiert werden. Ein Beispiel hierfür ist das nicht energieoptimale Fahrprofil in Abbildung 3.2. [236]

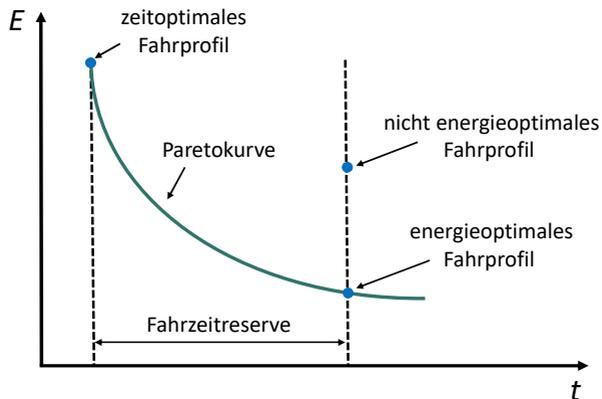


Abbildung 3.2: Pareto kurve aus energie- und zeitoptimalen Fahrprofilen nach [236]

Ziel für den energieeffizienten und pünktlichen Betrieb von Schienenfahrzeugen ist es, für jede zur Verfügung stehende Fahrzeitreserve das Fahrprofil mit dem geringsten Energiebedarf zu wählen.

3.2 Bewertung und Auswahl von Methoden zur Berechnung von Fahrprofilen

Kapitel 1.2.3 stellt fünf verschiedene Möglichkeiten aus der Forschung dar, wie energieeffiziente und pünktliche Fahrprofile berechnet werden können. Alle Verfahren werden bereits für Schienenfahrzeuge eingesetzt. Im Folgenden wird erörtert, welche Verfahren sich zur Steigerung von Energieeffizienz und Pünktlichkeit sowie für eine subsequente Applikation in einem Assistenzsystem insbesondere im System Straßenbahn eignen.

Gegenstand der Forschung dieser Dissertation ist die Quantifizierung des Verbesserungspotentials von Energieeffizienz und Pünktlichkeit durch die berechneten Fahrprofile. Des Weiteren sollen die ermittelten Geschwindigkeitstrajektorien ohne Einschränkungen in einem Fahrerassistenzsystem umgesetzt werden können. Daraus resultieren Anforderungen an die Modellierung des Fahrzeugs sowie die Notwendigkeit der Berücksichtigung weiterer *Randbedingungen* und Steuergrößen des Systems Straßenbahn. Zunächst müssen nichtlineare Dynamiken des Antriebsstrangs und der Fahrwiderstände im *Fahrzeugmodell* abgebildet werden. Als weitere Nebenbedingungen müssen die Berechnungsverfahren Unterscheidungen zwischen regenerativem und nicht regenerativem Bremsen sowie die Berücksichtigung von Steigungen, Kurvenradien und Geschwindigkeitsbeschränkungen ermöglichen. Wenn sowohl die Modellierungsanforderungen als auch die Anforderungen an die Randbedingungen erfüllt sind, können durch das jeweilige Verfahren *valide* Fahrprofile berechnet werden.

Herausfordernd bei Straßenbahnen sind zudem die variablen betrieblichen Randbedingungen. Lediglich an zentralen Haltepunkten wie dem Hauptbahnhof ist bei Straßenbahnen eine Haltedauer im Fahrplan ausgewiesen [115]. Variable Haltedauern durch ein erhöhtes oder verringertes Fahrgastaufkommen wirken sich direkt auf die verfügbare Fahrzeitreserve aus. Dadurch gestalten sich Fahrzeiten im System Straßenbahn variabler als im Vollbahn- oder

Metrobereich. Durch die variablen Fahrzeiten ist die Möglichkeit einer stetigen Neuberechnung der Geschwindigkeitstrajektorie notwendig, da nicht für alle möglichen Szenarien ein optimales Fahrprofil vorberechnet werden kann. Zum Einsatz in einem Fahrerassistenzsystem muss diese Neuberechnung *onlinefähig* sein, damit der Fahrer die Geschwindigkeitsvorgabe direkt umsetzen kann.

Aus diesen Anforderungen werden Bewertungskriterien für die fünf Verfahren aus Kapitel 1.2.3 abgeleitet. Die Kriterien umfassen die Berücksichtigung von Nichtlinearitäten im *Fahrzeugmodell*, die Möglichkeit zusätzliche *Randbedingungen* in der Optimierung definieren zu können sowie die *Onlinefähigkeit* des Berechnungsverfahrens. Abbildung 3.3 zeigt den Vergleich der fünf Verfahren hinsichtlich der Bewertungskriterien. Verglichen werden der linear quadratische Regler (LQR), die Berechnung mit Metaheuristiken, der modellprädiktive Regler (MPC), Deep Reinforcement Learning (Deep-RL) sowie Dynamic Programming (DP).

Verfahren	Fahrzeugmodell	Randbedingungen	Onlinefähigkeit
LQR	linear	✗	✓
Metaheuristiken	linear	✗	✓
MPC	nichtlinear	beliebig	(✓)
Deep-RL	nichtlinear	beliebig	✓
DP	nichtlinear	beliebig	✗

Abbildung 3.3: Vergleich der im Stand der Technik und Wissenschaft vorgestellten Verfahren zur Berechnung energieeffizienter und pünktlicher Fahrprofile für Straßenbahnen

Sowohl beim LQR als auch bei den Metaheuristiken muss das aus dem Antriebsstrang und Fahrwiderständen bestehende *Fahrzeugmodell* zur Lösung

der algebraischen Riccati-Gleichung linearisiert werden [74]. MPC [187], Deep-RL [199] und Dynamic Programming [16] erlauben eine nichtlineare Modellierung der Systemdynamiken.

Die Berücksichtigung weiterer *Randbedingungen* für die Optimierung ist mit LQR und Metaheuristiken nicht direkt umsetzbar [74]. Für MPC, Deep-RL und Dynamic Programming können beliebig viele *Randbedingungen* zur Optimierung hinzugezogen werden [16, 187, 199].

Im Hinblick auf die *Onlinefähigkeit* zeichnen sich LQR, Metaheuristiken und Deep-RL durch schnelle Berechnungszeiten aus. Modellprädiktive Regler sind bedingt *onlinefähig* [187]. Abhängig vom gewählten MPC-Verfahren muss gegebenenfalls der Prädiktionshorizont oder die Frequenz reduziert werden, um eine *Onlinefähigkeit* zu garantieren [187]. Dynamic Programming ist nicht in der Lage, *online* ohne Vereinfachungen ein Fahrprofil zu berechnen. Dynamic Programming kann jedoch in einzelnen Fällen als offline berechnete Referenz für andere Verfahren dienen, um einen Abgleich mit dem theoretischen Optimum durchzuführen. [87]

Zur Zielerreichung der Dissertation werden hohe Anforderungen an die Simulationsqualität gestellt, um *valide* Ergebnisse zu ermitteln. Aufgrund der Linearisierung des Fahrzeugmodells und der Herausforderung bei der Integration zusätzlicher Steuergrößen kann mit LQR und Metaheuristiken kein *valides* Modell erstellt werden [74]. Im Gegensatz dazu können Optimierungen mit MPC, Deep-RL sowie Dynamic Programming mit *validen* Modellen von Fahrzeug, Betrieb und Infrastruktur durchgeführt werden [87, 239, 253].

Zusammenfassend zeigt sich, dass sowohl die modellprädiktive Regelung als auch Deep Reinforcement Learning grundsätzlich für die Anwendung geeignet sind. Die linear quadratische Regelung sowie die Metaheuristiken haben zwar geringe Berechnungszeiten, können jedoch keine validen Ergebnisse garantieren. Dynamic Programming ist aufgrund der fehlenden Onlinefähigkeit nicht für den Einsatz als Fahrerassistenzsystem geeignet.

Die modellprädiktive Regelung wird seit mehreren Jahrzehnten erfolgreich

für die Lösung regelungstechnischer Probleme eingesetzt [187]. Die Bandbreite reicht von Regelungen von Anlagen in der Chemie oder der Fabrikautomatisierung [165] bis hin zur Trajektorienberechnung für hochautomatisierte Fahrfunktionen [14]. Deep Reinforcement Learning zeigt ein vergleichbares Spektrum an Anwendungen durch den Einsatz in Produktionssystemen [69] sowie zur Steuerung von Fahrzeugen [73]. Vergleiche der beiden Verfahren haben in der Literatur in verschiedenen Fällen gezeigt, dass ein trainierter Deep-RL-Agent vergleichbare Ergebnisse zu einem MPC liefert und dabei Vorteile in der Rechenzeit aufweist [88, 136, 193]. Methoden des Deep Reinforcement Learnings haben das Potential, die Allgemeingültigkeit einer modellprädiktiven Regelung mit den Rechenzeiten der linear quadratischen Regelung zu kombinieren. Dieses Potential soll im Rahmen dieser Dissertation untersucht werden.

Daher wird in dieser Dissertation zur onlinefähigen Berechnung von Fahrprofilen zum energieeffizienten und pünktlichen Betrieb von Straßenbahnen Deep Reinforcement Learning angewandt. Neben diesem Verfahren wird für ausgewählte Anwendungsfälle ebenfalls Dynamic Programming verwendet. Dies ermöglicht eine Einordnung der durch Deep-RL ermittelten Fahrprofile in Bezug auf eine optimale Lösung.

Wie in Kapitel 2.1.4.1 dargestellt gibt es eine Vielzahl an Deep-RL-Algorithmen. Die von den Deep-RL-Agenten ermittelten Fahrprofile sollen mit denen der Fahrer aus dem regulären Fahrgastbetrieb verglichen werden. Aus diesem Grund müssen die Agenten die Möglichkeit haben, in vergleichbarer Form auf die Steuerung des Fahrzeugs Einfluss zu nehmen. Fahrer können über den Fahrhebel kontinuierlich die Zugkraft des Fahrzeugs einstellen.

Diese Bedingung schließt Q-Learning Verfahren aus, da hier eine Diskretisierung des Aktionsraums vorgenommen wird. Sowohl Algorithmen der Policy-Optimierung und Actor-Critic-Methoden erlauben kontinuierliche Aktions- und Beobachtungsräume. In vergleichbaren Anwendungen zeigen Actor-Critic-Methoden einen stabileren Trainingsprozess und eine bessere Konvergenz. [53]

Als Weiterentwicklung des DDPG-Algorithmus eliminiert der TD3-Algorithmus durch das Hinzufügen eines zweiten Critic-Netzwerks den Überschätzungs-Bias [78]. TD3 wird, wie in Kapitel 2.1.4.2 beschrieben, bereits zur Steuerung und Regelung in kontinuierlichen Aktions- und Zustandsräumen verwendet. Im Rahmen dieser Dissertation soll daher die Eignung von TD3 für die Optimierung von Fahrprofilen untersucht werden.

3.3 Zielsetzung und Forschungshypothesen

In dieser Dissertation sollen Deep Reinforcement Learning-Agenten trainiert werden, welche in der Lage sind, in Abhängigkeit der variablen betrieblichen Randbedingungen der Straßenbahn energieeffiziente und pünktliche Fahrprofile zu berechnen. Die trainierten Agenten sollen ebenfalls auf ihre Fähigkeiten zum Wissenstransfer in unbekanntem Szenarien sowie auf unbekanntem Streckenabschnitten untersucht werden. Zur Erfüllung der Zielsetzung werden die folgenden Forschungshypothesen im Rahmen der Dissertation untersucht.

Forschungshypothese 1 – Mit dem Einsatz von Deep-RL-Agenten kann die Energieeffizienz und Pünktlichkeit gesteigert werden.

Der Stand der Forschung hat aufgezeigt, dass in bisherigen Implementierungen der Lösungsraum durch die Diskretisierung der Aktionen eingeschränkt ist und kein Vergleich mit menschlichen Fahrern gezogen wird. Im Rahmen dieser Dissertation soll ein Deep-RL-Agent mit kontinuierlichem Aktionsraum trainiert werden. Dieser Deep-RL-Agent wird mit einem durch Dynamic Programming ermittelten theoretischen Optimum sowie mit Fahrern aus dem regulären Fahrgastbetrieb hinsichtlich Pünktlichkeit und Energieeffizienz verglichen. Bei den Fahrern wird zusätzlich zwischen dem durchschnittlichen, dem pünktlichsten und dem Fahrer mit dem energieeffizientesten Fahrprofil auf den betrachteten Streckenabschnitten unterschieden.

Forschungshypothese 2 – Innerhalb eines Szenarios können Deep-RL-Agenten einen Wissenstransfer erbringen.

In bisherigen Forschungsarbeiten werden Deep-RL-Agenten nur auf einem spezifischen Szenario trainiert und darauf ausgewertet. Im Straßenbahnbereich hat die Fahrzeitreserve eine hohe Varianz, so dass ein Training von Agenten auf jedes Szenario zu zeitintensiv wäre. Um den Nachweis einer Praxistauglichkeit zu erbringen, muss die KI in der Lage sein, auch unter vom Training abweichenden Szenarien energieeffizienter und pünktlicher als die Fahrer zu fahren.

Forschungshypothese 3 – Deep-RL-Agenten können das erlernte Wissen auf einen neuen Anwendungsfall transferieren.

Durch Betriebsstörungen kann es teils zu unerwarteten Umwegfahrten kommen. Um die Reaktion der KI hierauf zu evaluieren, wird diese auf einem ihr unbekanntem Streckenabschnitt getestet und erneut mit der Pünktlichkeit und dem Energiebedarf der Fahrer aus dem regulären Fahrgastbetrieb verglichen. Neben dem Wissenstransfer soll dieser Test sicherstellen, dass die KI während des Trainings nicht die Strecke auswendig lernt, sondern auf Basis der gegebenen Streckencharakteristika und der vorliegenden Fahrzeitreserve die korrekten Fahrentscheidungen trifft.

Forschungshypothese 4 – Der KI-Trainingsprozess kann durch den Einsatz datengetriebener Modellierungsverfahren verbessert werden.

Deep-RL-Implementierungen in anderen Forschungsbereichen haben gezeigt, dass bis zum Erreichen von zu Menschen vergleichbaren Ergebnissen viele Trainingsschritte nötig sind [108]. Selbst mit optimierten Umgebungen werden teils bis zu 200 Millionen Trainingsschritte [91, 148] in simplen Anwendungsfällen oder mehrere hundert Stunden Trainingszeit [90] in Physiksimulationen zum Training von Robotern benötigt.

Bei Verwendung konventioneller Multiphysik-Simulationsmodelle zur Bestim-

mung des Energiebedarfs kann daher keine Konvergenz des KI-Trainings garantiert werden. Aus diesem Grund wird im Rahmen der Dissertation die Verwendung und Parametrierung datengetriebener Modelle zur Berechnung des Energiebedarfs untersucht, um die Rechenzeit zu beschleunigen und damit den Trainingsprozess des Deep-RL-Agenten zu verbessern.

3.4 Lösungsansatz und Vorgehensweise

Der Lösungsansatz in Abbildung 3.4 soll die Verifizierung der aufgezeigten Forschungshypothesen aus Kapitel 3.3 ermöglichen.

Der Deep-RL-Ansatz in dieser Dissertation wird gesamtheitlich betrachtet. Daher müssen flächendeckende Langzeitmessungen im regulären Fahrgastbetrieb durchgeführt werden, um eine valide Datenbasis zu generieren. Dafür und für weitere Forschungsarbeiten wird die Karlsruher Messstraßenbahn mit Messtechnik ausgerüstet.

Auf Basis der gesammelten Daten wird das Deep-RL-System aus Umgebungsmodell, Aktions- und Beobachtungsraum, aufgestellter Rewardfunktion und ausgewähltem Algorithmus modelliert.

Im aufgebauten Deep-RL-System wird anschließend die KI auf ausgewählten Szenarien trainiert und getestet. Dabei werden stets Vergleiche mit den Fahrern hinsichtlich Energiebedarf und Pünktlichkeit durchgeführt.

Der beschriebene Ansatz ermöglicht durch die Validierung des modellierten Deep-RL-Systems Ergebnisse mit einer hohen Simulationsqualität. Dadurch wird sichergestellt, dass die Ergebnisse aus Training und Test der KI mit den Fahrern aus dem regulären Fahrgastbetrieb vergleichbar sind.

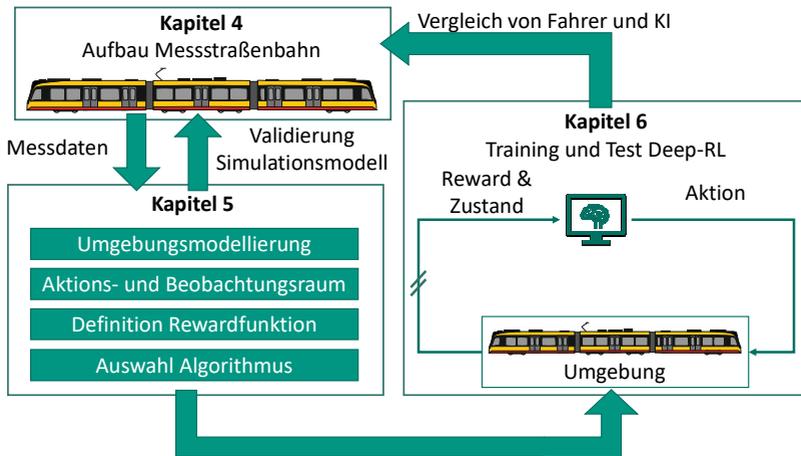


Abbildung 3.4: Lösungsansatz zum Training und zum Test von Deep Reinforcement Learning Agenten mit Vergleich zum regulären Fahrgastbetrieb

Aus dem Lösungsansatz leitet sich die weitere Vorgehensweise für die Dissertation ab, welche in Abbildung 3.5 dargestellt ist.

Zunächst wird in Kapitel 4 der Aufbau der Karlsruher Messstraßenbahn beschrieben, mit welcher die Messdaten aus dem regulären Fahrgastbetrieb erfasst werden. Daten der Infrastruktur und des Betriebs werden zu den Messdaten aggregiert, um einen gesamtheitlichen Datensatz aus Fahrzeug, Betrieb und Infrastruktur zu schaffen. Abschließend wird die Datengrundlage mittels theoretischer Grundlagen validiert, um sicherzustellen, dass die Aggregation der Infrastrukturdaten korrekt ist. Anschließend erfolgt eine Evaluation, ob die Datensätze den Ansprüchen an die Simulationsqualität genügen.

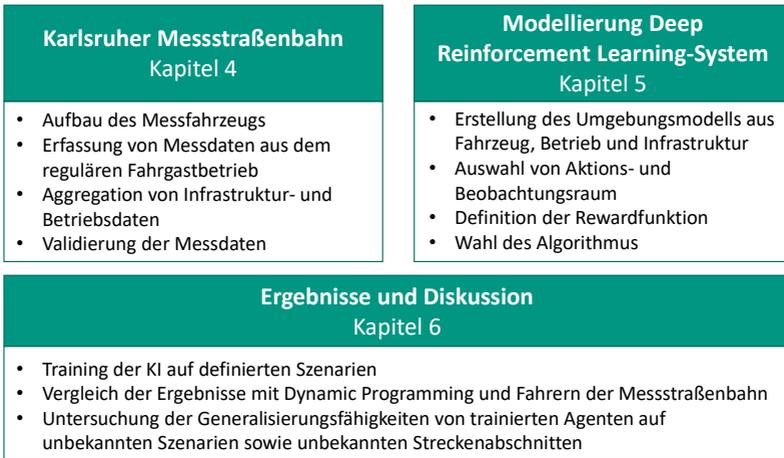


Abbildung 3.5: Vorgehensweise in der Dissertation

Aufbauend auf der Datengrundlage wird in Kapitel 5 das Deep-RL-System modelliert. Zunächst wird das Umgebungsmodell bestehend aus Fahrzeug, Betrieb und Infrastruktur aufgebaut. Anschließend werden der Beobachtungs- und Aktionsraum der KI sowie der verwendete Deep-RL-Algorithmus definiert. Abschließend wird die Rewardfunktion definiert, anhand derer die KI während des Trainings energieeffizientes und pünktliches Fahren erlernen soll.

Darauffolgend wird in Kapitel 6 der Deep-RL-Agent auf ausgewählte Szenarien trainiert und mit den Fahrtrajektorien der Fahrer aus dem regulären Fahrgastbetrieb sowie mit von Dynamic Programming ermittelten Fahrprofilen verglichen. Abschließend werden die Fähigkeiten zum Transferlernen der KI auf unbekanntem Szenarien sowie unbekanntem Streckenabschnitten getestet.

4 Karlsruher Messstraßenbahn

Im vierten Kapitel erfolgt die Beschreibung zum Aufbau der Karlsruher Messstraßenbahn (vgl. Abbildung 4.1). Durch die Messdaten und weitere aggregierte Daten wird anhand eines strukturierten Prozesses eine Datengrundlage geschaffen, welche mit Werten aus der Theorie und der Literatur validiert wird. Damit wird sichergestellt, dass die Datengrundlage den Anforderungen an die Simulationsqualität entspricht, um einen späteren Abgleich zwischen den Fahrprofilen der Fahrer und der trainierten KI zu ermöglichen. Des Weiteren wird auf Basis der Daten der Karlsruher Messstraßenbahn eine Klassifikation des Fahrverhaltens vorgenommen. Diese Klassifikation kann im weiteren Verlauf der Dissertation als zusätzliche Vergleichsmetrik zwischen Fahrer und KI verwendet werden.

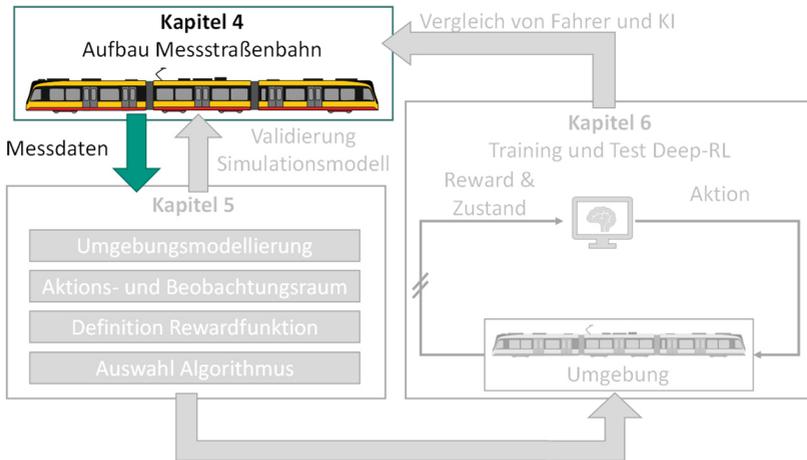


Abbildung 4.1: Einordnung des vierten Kapitels im Lösungsansatz

4.1 Hintergründe und Grundlagen

4.1.1 Einordnung der Karlsruher Messstraßenbahn in den Stand der Technik und Wissenschaft

Zur Steigerung der Attraktivität und Wirtschaftlichkeit des ÖPNV sind umfassende Systemkenntnisse zu den Vorgängen im Netz und im Fahrzeug nötig. Fahrzeughersteller, Systemlieferanten und Betreiber sind daher seit Jahren interessiert, Daten aus dem regulären Fahrgastbetrieb nutzbringend einzusetzen. Aus den Daten sollen Optimierungen an Fahrzeug, Betrieb und Infrastruktur durchgeführt werden. Diese Verbesserungen können sowohl in der aktuellen Fahrzeugflotte umgesetzt werden, als auch in die Entwicklung zukünftiger Fahrzeuggenerationen fließen.

Verschiedene Forschungsprojekte im Straßenbahnbereich verfolgen das Ziel, durch die Erfassung von Daten Optimierungspotentiale zu erschließen.

Ein beispielhaftes Projekt stellt die *EcoTram* in Wien dar. Dabei handelt es sich um ein Konsortialprojekt der TU Wien, der Siemens Mobility GmbH, der SCHIG mbH, der Rail Tec Arsenal sowie Vossloh Kiepe. Von 2009 bis 2014 wurden durch Datenerfassungssysteme die Heizungs-, Klimatisierungs- und Lüftungsanlagen der Straßenbahn untersucht. Das Ziel war die Einsparung von Energie sowie die Steigerung des Komforts für die Fahrgäste. Aus den Messungen wurden Maßnahmenpakete abgeleitet, welche testweise wiederum im Fahrgastbetrieb erprobt wurden. Dazu zählen die prädiktive Heizung und Klimatisierung hinsichtlich der erwarteten Fahrgastzahlen und der klimatischen Bedingungen sowie die Beklebung der Fenster mit speziellem Material zur Verminderung der Sonneneinstrahlung. [197]

Dieses Projekt zielt auf die Messung und Optimierung einzelner Komponenten bzw. Teilsysteme ab. Im Gegensatz dazu verfolgt die *Messstraßenbahn der TU Dresden* einen ganzheitlichen Ansatz bei der Datenerfassung. Das Fahrzeug ist seit 2009 im regulären Fahrgastbetrieb im Einsatz. Der Fokus des Forschungsprojekts liegt zwar in der Aufzeichnung und

Auswertung mechanischer Parameter, dennoch werden auch elektrische Größen wie die Energieflüsse im System erfasst. [55, 56]

Vergleichbare Projekte gibt es ebenfalls im Vollbahnbereich. Die Schweizerische Südostbahn nutzt Beschleunigungssensoren zur Überwachung des Schienenzustands während des regulären Fahrgastbetriebs [98]. Im Forschungsprojekt *HavenZuG* wurde eine Güterlokomotive mit Beschleunigungssensoren sowie Kameras ausgestattet, um ebenfalls eine Zustandsüberwachung der Schieneninfrastruktur durchzuführen [12, 13]. Die Deutsche Bahn hat mit dem *advanced TrainLab* ein Plattform-Fahrzeug geschaffen, anhand dessen Messungen zu Fahrzeugkomponenten und zur Infrastruktur auf einer Teststrecke ermöglicht werden [150]. Des Weiteren können neue Assistenzsysteme und die Einsatzpotentiale von 5G untersucht werden [150].

4.1.2 Datenerfassung durch die Karlsruher Messstraßenbahn

In diese Reihe exemplarischer Projekte im Straßenbahnbereich reiht sich die Karlsruher Messstraßenbahn ein. Dabei handelt es sich um ein Kooperationsprojekt zwischen der Albtal-Verkehrs-Gesellschaft mbH (AVG) und dem Institut für Fahrzeugsystemtechnik (FAST) des KIT. Ein mit dem Fahrzeug in Abbildung 4.2 baugleicher NET 2012 wird mit Sensoren und einem Datenerfassungssystem ausgerüstet. Die technischen Parameter des Stadtbahnfahrzeugs sind in Tabelle 4.1 aufgelistet. Das Fahrzeug verfügt über eine Zulassung nach BOStrab sowie der Eisenbahn-Bau- und Betriebsordnung (EBO) und kann daher auch auf den Linien der S1 und S11 im gesamten Karlsruher Gleichspannungsnetz eingesetzt werden.

Das Datenerfassungssystem ist rein passiv, wodurch keine Neuzulassung des Fahrzeugs erforderlich ist. Das Messsystem ist über das gesamte Fahrzeug verteilt, um Kabellängen gering zu halten. Dadurch werden Interferenzen auf den Signalleitungen minimiert. Seit Mai 2019 wird das Fahrzeug im regulären

Fahrgastbetrieb eingesetzt. Seither werden mehr als 150 Messgrößen aufgezeichnet. Durch eine Systemerweiterung Ende 2020, mit welcher der Zugriff auf den sicherheitsrelevanten CAN-Bus ermöglicht wurde, werden mehr als 250 Messgrößen übertragen. Nahezu alle Messdaten werden mit einer Abtastrate von 10 Hz aufgezeichnet. Ausnahme sind die Beschleunigungssensoren im vorderen und hinteren Wagenkasten sowie an den Traktionsdrehgestellen. Diese Größen werden mit 2,4 kHz abgetastet, um höherdynamische Vorgänge aufzeichnen zu können. Die Datenübertragung erfolgt zyklisch über eine LTE Verbindung. Mit dieser ist auch eine Fernwartung des Systems möglich. [157] Am Institut wurde ein Datenbanksystem aufgebaut, welches die strukturierte Analyse der Daten ermöglicht [99]. Weitere Ausführungen zum Systemaufbau und Auswertungsbeispiele zu Nebenverbrauchern und zur Zustandsüberwachung der Schieneninfrastruktur sind [206, 208-211] zu entnehmen.

Tabelle 4.1: Fahrzeugdaten des in Karlsruhe eingesetzten Messfahrzeugs nach [234]

Fahrzeugparameter NET 2012	
Länge	37.200 mm
Masse (leer)	58 t
Masse maximal	83 t
Niederfluranteil	80 %
Türen	5
Sitz-/Stehplätze	106 / 166
Oberleitungsspannung	750 V DC
Höchstgeschwindigkeit	80 km/h
Zulassungen	BOStrab / EBO
Traktionsleistung (Nennleistung)	600 kW
Achsfolge	Bo'2'2'Bo'



Abbildung 4.2: NET 2012 im Betriebshof (Bild: Philip Otto)

4.2 Datengrundlage

Während des täglichen Betriebs werden durch die Karlsruher Messstraßenbahn lediglich fahrzeugtechnische Größen aufgezeichnet. Die weitere Modellierung und Simulation setzen jedoch voraus, dass ein vollständiges Abbild aus Fahrzeug, Betrieb und Infrastruktur vorhanden ist. Dadurch können spätere Simulationsergebnisse mit den Fahrprofilen von Fahrern aus dem regulären Fahrgastbetrieb verglichen werden und die Modellierungsqualität wird sichergestellt.

Daher müssen die aufgezeichneten Daten der Messstraßenbahn mit weiteren Datenquellen der Infrastruktur und des Betriebs aggregiert werden. Anschlie-

ßend ist es erforderlich, diese durch die Aggregation erzeugte Datengrundlage zu validieren. Die Validierung findet anhand der theoretischen Fahrwiderstände von Schienenfahrzeugen nach Kapitel 2.3 statt. Die anschließenden Unterkapitel sind anhand des Knowledge Discovery in Databases (KDD)-Prozesses (vgl. Kapitel 2.1.1) nach Fayyad [66] strukturiert. Die aus dem KDD-Prozess abgeleitete Struktur für diese Unterabschnitte ist in Abbildung 4.3 dargestellt.

Zunächst werden die für diese Dissertation relevanten Daten der Messstraßenbahn identifiziert und ausgewählt. Im darauffolgenden Schritt der Datenvorverarbeitung gilt es, die Daten von systematischen Fehlern zu bereinigen und die weiteren Datenquellen hinzuzufügen. In der Datentransformation werden die Daten in die für die Validierung notwendige Form gebracht und aus den Energiemessungen die Fahrwiderstände errechnet. Im darauffolgenden Data Mining werden die Fahrwiderstandsdaten der Messstraßenbahn mit den Theorie- und Literaturwerten verglichen. Abschließend erfolgt eine Diskussion und Evaluation der Ergebnisse, in welcher Qualität die Aggregation der Infrastrukturdaten erfolgt ist und wie die Datengrundlage für die weitere Modellierung und Simulation genutzt werden kann.

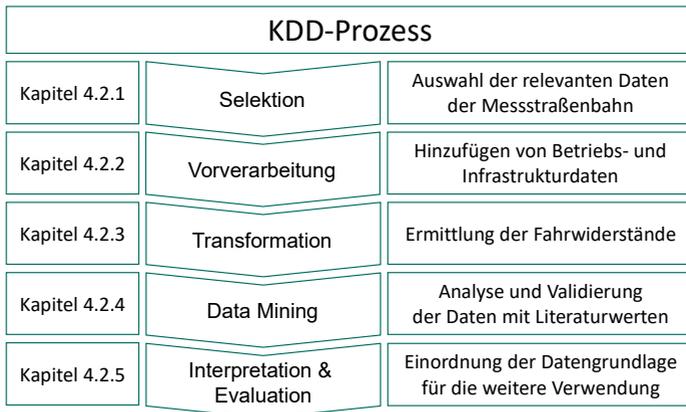


Abbildung 4.3: KDD-Prozess zur Schaffung und Validierung der Datengrundlage

4.2.1 Selektion

Aus den Messdaten des regulären Fahrgastbetriebs werden die für die Dissertation relevanten Daten ausgewählt. Die Messgrößen, deren Gruppierung und der Auswahlgrund der jeweiligen Größe sind in Tabelle 4.2 aufgelistet.

Tabelle 4.2: Ausgewählte Messgrößen für die Dissertation

Gruppe	Messgrößen	Auswahlgrund
Elektrische Parameter	Traktionsströme	Untersuchung zum
	Oberleitungsspannung	Traktionsenergiebedarf
Fahrzeugparameter	Bremswiderstandsstrom	Untersuchung zu
	Bremswiderstandsspannung	Bremsenergieverlusten
Fahrzeugparameter	Fahrzeuggeschwindigkeit	Untersuchung zum
	Türöffnungszeiten	Traktionsenergiebedarf
Fahrgastkomfort	Triaxiale Beschleunigungssensoren am vorderen und hinteren Fahrzeugende	Haltestellenerkennung
		Untersuchung zum Fahrgastkomfort und zur Längsbeschleunigung des Fahrzeugs
Weitere Parameter	GPS-Koordinaten	Örtliche Zuordnung der Fahrten
	Linieninformationen	Eindeutige Bestimmung der aktuellen Linie
	Uhrzeit	Betriebliche Zuordnung der Fahrten

4.2.2 Vorverarbeitung

In der Datenaufbereitung wird zunächst der initiale Datenbestand aus dem regulären Fahrgastbetrieb von systematischen Fehlern und Ausreißern bereinigt. Anschließend werden in mehreren Schritten die Infrastruktur- und Betriebsdaten zu den aufgezeichneten Daten der Karlsruher Messstraßenbahn hinzugefügt. Dies wird durch eine automatisierte Softwarelösung erreicht. Die daraus resultierende Datengrundlage soll die Basis für die spätere Fahrzeug-, Betriebs- und Infrastrukturmodellierung darstellen.

Infrastrukturmodellierung

Höhendaten stehen durch digitale Geländemodelle mit einer Auflösung von 1 m und Lagepläne der AVG zur Verfügung. Durch eine odometrie- und GPS-basierte Sensordatenfusion werden die einzelnen Messpunkte den Höhendaten zugeordnet. Die daraus resultierenden Höhenprofile sind exemplarisch für eine Fahrt auf der Linie S1 von Hochstetten nach Bad Herrenhalb sowie der Linie 4 vom Tivoli in die Waldstadt in Abbildung 4.4 (a) und (b) dargestellt. Die aufgezeigten Höhenprofile basieren auf den Linienverläufen von Dezember 2018 bis Dezember 2021 [115]. Der Großteil der Linien in Karlsruhe fährt durch die Innenstadt, wo es kaum Höhenunterschiede gibt. Die Linien S1 und S11 fahren in die Ausläufer des Nordschwarzwalds und überwinden dabei zum Teil mehr als 200 Höhenmeter. Aus den Höhendaten wird mit einem zentralen Differenzenquotienten die Steigung berechnet. Gegenüber den konventionellen einseitigen Differenzenquotienten erzeugt der zentrale Differenzenquotient eine genauere numerische Ableitung, was in einer verbesserten Berechnung der Steigung resultiert.

Neben den Steigungen werden die Bogenradien durch eine Fahrweganalyse ermittelt. Auf Basis der aufgezeichneten Fahrten wird durch eine Mittelwertbildung der Trajektorien der Radius berechnet. Dadurch wird das Ergebnis nicht durch einzelne Ausreißer im GPS-Signal verfälscht.

Zusätzlich zu den Bogenradien und Steigungen sind für die spätere Modellierung des gesamten Bahnsystems ebenfalls die Streckenhöchstgeschwindigkeiten von Relevanz. Anhand des Buchfahrplans und des Geschwindigkeitshefts der AVG können diese Information zu den Messdaten aggregiert werden.

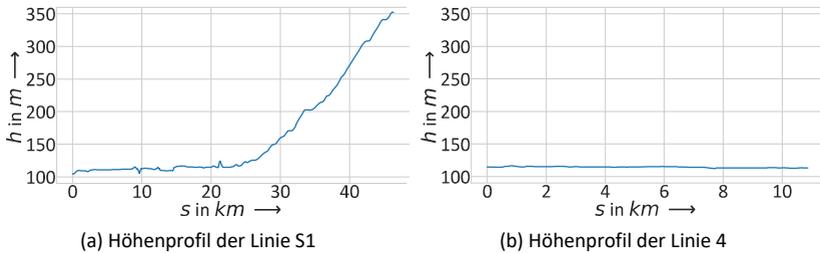


Abbildung 4.4: Ergebnis der Zuordnung der Höhendaten zu den jeweiligen Messpunkten der Messstraßenbahn für die Linie S1 (a) und die Linie 4 (b).

Betriebsmodellierung

Zur Analyse der Verspätungen und von Fahrzeitreserven über den gesamten Betriebstag ist es notwendig, den Fahrplan mit den Messdaten zu fusionieren. Aus dem initialen Datenbestand ist lediglich die aktuelle Linie bekannt, auf der die Messstraßenbahn verkehrt. Durch eine Fusion aus GPS-Daten, der Fahrzeuggeschwindigkeit sowie den Türöffnungszeiten können einzelne Haltestellen identifiziert werden. Durch die aufgezeichnete Uhrzeit kann über den gegebenen Fahrplan die korrekte Fahrt in der Fahrplantabelle zugewiesen werden. Dadurch sind Verspätungsberechnungen sowohl über die gesamte Fahrt als auch zwischen einzelnen Haltestellenabschnitten möglich.

Fahrgäste haben durch die Auswirkungen auf die Fahrzeugmasse einen nicht zu vernachlässigenden Einfluss auf den Energiebedarf. Des Weiteren führen Fahrgastwechsel mit vielen Fahrgästen häufig zu Verspätungen durch die damit verbundenen längeren Haltedauern. Die Messstraßenbahn verfügt über

kein Fahrgastzählsystem, so dass auf Fahrgastzählungen der AVG aus Langzeitaufzeichnungen zurückgegriffen wird. Diese Daten werden ebenfalls zum Messdatensatz hinzugefügt.

4.2.3 Transformation

Im Schritt der Datentransformation werden aus den aggregierten Daten die Fahrwiderstände berechnet, anhand derer die Validierung durchgeführt wird. Validiert werden der Laufwiderstand, der Steigungswiderstand sowie der Bogenwiderstand. Zudem werden die Daten in Gruppen unterteilt, damit eine wechselwirkungsfreie Analyse möglich ist.

Fahrwiderstandsberechnung

Da die Fahrwiderstände (vgl. Kapitel 2.3) nicht in den Messdaten enthalten sind, werden diese nach Formel 4-1 berechnet. Die Summe des gesamten Fahrwiderstands F_W und der Trägheitskraft F_a entspricht dem zeitlichen Integral der Traktionsleistung $P_{Traktion}$ über der gefahrenen Strecke $s_{Abschnitt}$. [131]

$$F_W + F_a = \frac{\int_{t_1}^{t_2} P_{Traktion} dt}{s_{Abschnitt}} \quad (4-1)$$

Gleichung 4-1 beinhaltet noch die Trägheitskraft. Um den Abgleich der Fahrwiderstände mit der Theorie durchzuführen, muss die Trägheitskraft bestimmt werden. Die Berechnung der Trägheitskraft F_a erfolgt nach Formel 4-2a. F_a ergibt sich aus der im Streckenabschnitt umgesetzten kinetischen Energie geteilt durch die Länge des Streckenabschnitts. Abschnitte mit höherer Ausfahrtsgeschwindigkeit v_{Ende} als Einfahrtsgeschwindigkeit v_{Start} haben eine positive Trägheitskraft. Ist die Einfahrtsgeschwindigkeit höher als die Ausfahrtsgeschwindigkeit resultiert eine negative Trägheitskraft. Lediglich auf Abschnitte mit konstanter Geschwindigkeit zu filtern, würde die

Datenbasis zur Analyse zu stark reduzieren. Der resultierende Fahrwiderstand F_W wird durch Gleichung 4-2b beschrieben. [131]

$$F_a = \frac{\frac{1}{2} \cdot m_{Fzg} \cdot v_{Ende}^2 - \frac{1}{2} \cdot m_{Fzg} \cdot v_{Start}^2}{s_{Abschnitt}} \quad (4-2a)$$

$$F_W = \frac{\int_{t_1}^{t_2} P_{Traktion} dt - \frac{1}{2} \cdot m_{Fzg} \cdot v_{Ende}^2 + \frac{1}{2} \cdot m_{Fzg} \cdot v_{Start}^2}{s_{Abschnitt}} \quad (4-2b)$$

Die Masse des Fahrzeugs m_{Fzg} wird durch die Leermasse des Fahrzeugs m_{Leer} und den Fahrgastzahlen aus den Passagierstatistiken der AVG approximiert. Des Weiteren wird ein Massenzuschlagsfaktor von 0,05 angenommen, welcher durch rotierende Teile beim Beschleunigen und Verzögern bedingt ist. [131]

$$m_{Fzg} = m_{Leer} \cdot 1,05 + 70 \text{ kg} \cdot n_{Passagiere} \quad (4-3)$$

Abschnittsauswahl

Für die Analyse der Fahrwiderstände müssen zunächst geeignete Abschnitte ausgewählt werden. Die Abschnitte sollen möglichst wechselwirkungsfrei zwischen Gleisbögen und Steigungen sein, damit ein Abgleich mit Literaturwerten möglich ist.

Die Geschwindigkeit in den Abschnitten muss größer als 10 km/h sein. In den Geschwindigkeitsbereichen unterhalb des Grenzwertes spielt meist die Trägheitskraft eine übergeordnete Rolle, da entweder verzögert oder beschleunigt wird.

Des Weiteren muss die zurückgelegte Distanz im Abschnitt mindestens 30,6 m betragen. Aus technischen Zeichnungen des Fahrzeugs wurde abgeleitet, dass die Positionierung des GPS-Sensors einen Abstand von 5,4 m zum

vorderen und 25,2 m zum hinteren Drehgestell aufweist. Falls dies nicht berücksichtigt wird, kann nicht garantiert werden, dass sich mindestens ein Teil des Fahrzeugs im ausgewählten Abschnitt befindet.

Zudem dürfen keine Ausfälle des Messsystems im gewählten Abschnitt auftreten und der Abschnitt muss mindestens 5 Sekunden lang sein.

Für die weitere Steigungs- und Gleisbogenanalyse werden die identifizierten Abschnitte in weitere Untergruppen unterteilt. Die Unterteilung erfolgt getrennt für die beiden Analysen, um eine Wechselwirkungsfreiheit zwischen Gleisbögen und Steigungen zu garantieren.

Für die Steigungsanalyse werden zunächst alle Abschnitte mit Bogenradien $R \leq 150 \text{ m}$ aussortiert. Höhere Grenzwerte für den Bogenradius haben nach Leineweber [131] zu keiner Verbesserung des Ergebnis geführt und lediglich die Anzahl der analysierbaren Abschnitte reduziert. Dies ist dadurch bedingt, dass größere Bogenradien keinen messbaren Beitrag zum Fahrwiderstand leisten (vgl. Abbildung 2.12). In der Gruppe der ebenen Strecke darf die betragsmäßige Steigung im Abschnitt nicht größer 2 ‰ sein. Steigungen größer 5 ‰ werden der Gruppe mit positiver Steigung zugeordnet. Bei einer Steigung von kleiner -5 ‰ erfolgt die Zuordnung zur Gruppe der negativen Steigung. Abschnitte mit betragsmäßigen Steigungen zwischen 2 und 5 ‰ werden aussortiert, wodurch eine möglichst trennscharfe Analyse gewährleistet werden soll.

Zur Analyse der Gleisbögen werden lediglich Abschnitte mit einer betragsmäßigen Steigung von maximal 2 ‰ verwendet.

In den einzelnen Abschnitten darf ebenfalls der Bremswiderstand nicht verwendet werden. Bremswiderstandsstrom und -spannung werden zwar vom Messsystem aufgezeichnet, jedoch nur an einem der vier Bremswiderstände. Die vier Bremswiderstände werden im täglichen Betrieb nicht symmetrisch belastet, so dass die exakte Leistung am Bremswiderstand nicht bestimmbar ist. Dies kann zwar nach [156] über weitere Größen des Fahrzeugbus appro-

ximiert werden, jedoch nicht mit der geforderten Genauigkeit, dass die Leistung nach Gleichung 4-1 berechnet werden kann. Daher werden Abschnitte aussortiert, insofern Bremsenergie im Bremswiderstand umgesetzt wird.

4.2.4 Data Mining

Die definierten Abschnitte aus der Datentransformation werden nun hinsichtlich des Laufwiderstandes, des Steigungswiderstandes und des Bogenwiderstandes visualisiert und mit Werten aus der Literatur verglichen.

Laufwiderstand

Abbildung 4.5 zeigt den aus den Messdaten ermittelten Laufwiderstand über der Fahrzeuggeschwindigkeit. Jeder einzelne Datenpunkt repräsentiert die Fahrt in einem definierten Abschnitt nach Kapitel 4.2.4. Die Geschwindigkeit ist die Durchschnittsgeschwindigkeit im jeweiligen Abschnitt. Die Fahrten mit einer betragsmäßigen Steigung von mehr als 5 ‰ (Gruppe 2 und Gruppe 3) sind ausgegraut hinterlegt und fließen nicht in die Analyse ein. Die blauen Datenpunkte aus Gruppe 1 sind Fahrten auf ebener Strecke bis zu einer betragsmäßigen Steigung von 2 ‰ mit herausgerechneter Trägheitskraft.

Die Verteilung der Datenpunkte ist nicht gleichmäßig über den Geschwindigkeitsbereich. Durch den vermehrten Einsatz im Innenstadtbereich stehen mehr Datenpunkte im Geschwindigkeitsbereich bis 50 km/h zur Analyse zur Verfügung als im Bereich zwischen 50 und 80 km/h.

Durch alle Datenpunkte der Gruppe 1 wird eine Regressionsfunktion ermittelt, welche in Abbildung 4.5 als grüne Kurve hinterlegt ist. Diese Regressionsfunktion berechnet sich nach dem Polynom aus Gleichung 2-14.

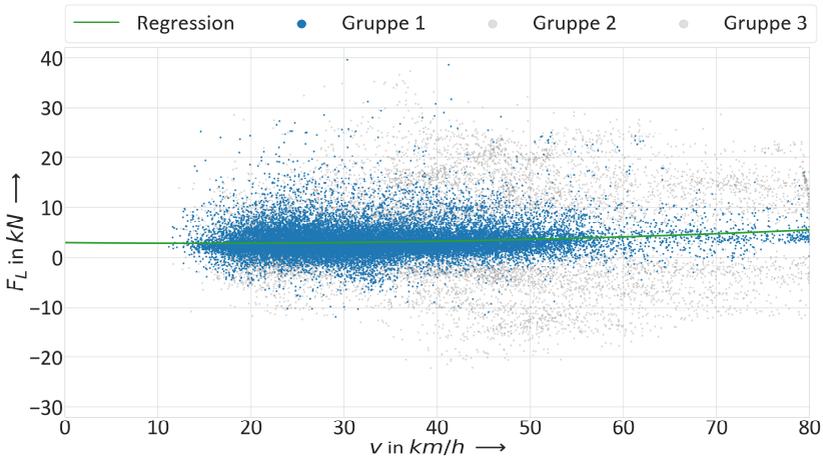


Abbildung 4.5: Analyse des Laufwiderstands der Messstraßenbahn auf ebener Strecke inklusive einer Regressionsfunktion durch die Datenpunkte

Zur Einordnung der ermittelten Regressionsfunktion des Laufwiderstands werden Werte aus Ausrollversuchen aus der Literatur hinzugezogen. Als Vergleichswerte dienen die Ausrollversuche nach Springmann mit einem GT8-70D/N. Durch die erhöhte Fahrzeugmasse des NET 2012 sowie der vergrößerten Querschnittsfläche wird die Fahrwiderstandskurve des GT8-70D/N angepasst. Die höhere Fahrzeugmasse geht linear in den Roll- und Reibungswiderstand ein. Aufgrund der erhöhten Querschnittsfläche der Fahrzeugfront vergrößert sich wiederum der Luftwiderstand. Zwischen dem Luftwiderstand und der Querschnittsfläche ist der Zusammenhang ebenfalls linear. Die Fahrzeugmasse des NET 2012 ist um 11,6 % höher, die Querschnittsfläche ist durch das höhere Fahrzeug um 5 % vergrößert. Der Vergleich der beiden Regressionskurven ist in Abbildung 4.6 dargestellt. Die grüne Kurve repräsentiert die Regression aus den Datenpunkten der Messstraßenbahn. Die orangene Kurve basiert auf Ausrollversuchen mit einem GT8-70D/N [194].

Die abweichende Ausprägung der durch die Messdaten ermittelten Laufwiderstandskurve kann durch die nicht einheitliche Datenbasis über den gesamten Geschwindigkeitsbereich bedingt sein. Zwischen 0 und 10 km/h kann der unterschiedliche Verlauf durch die fehlenden Daten in diesem Bereich erklärt werden.

Trotz der Diskrepanzen ordnet sich die ermittelte Regressionskurve in Bezug auf die absoluten Werte des Laufwiderstands vergleichbar ein. Geringe Abweichungen beim Laufwiderstand kommen beim Energiebedarf aufgrund der großen Einflüsse durch den Streckenwiderstand (vgl. Abbildung 2.11) weniger zu tragen.

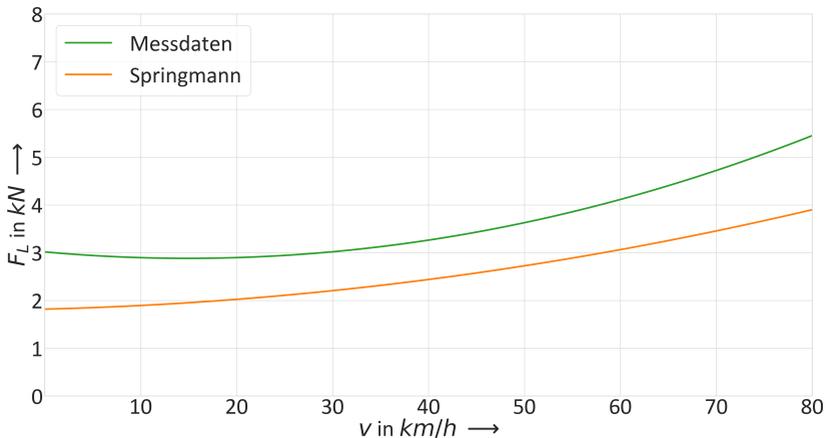


Abbildung 4.6: Vergleich der Regressionsfunktion des Laufwiderstandes der Messstraßenbahn mit Ausrollversuchen nach Springmann [194]

Steigungswiderstand

Abbildung 4.7 zeigt den aus den Datenpunkten ermittelten Steigungswiderstand der Messstraßenbahn über der Steigung in Promille auf. Die drei distinkten Gruppen aus der Datentransformation sind erkennbar.

In der Gruppe der negativen Steigungen sind weniger Datenpunkte als im Bereich der positiven Steigungen vorhanden. Hohe Steigungen treten im Karlsruher Streckennetz nahezu ausschließlich auf den Linien S1 und S11 im Schwarzwald auf (vgl. Abbildung 4.4 (a)). In diesen Gebieten sind jedoch weniger Fahrzeuge unterwegs, da der Takt ausgedünnter im Vergleich zum Innenstadtbereich ist. Fahrzeuge können ihre Bremsenergie nur zurückspeisen, wenn ein anderes Fahrzeug in der Nähe diese Bremsenergie aufnehmen kann. Ansonsten wird die Energie im Bremswiderstand in Wärme umgewandelt. Aufgrund dessen, dass auf den Strecken mit Gefälle häufiger gebremst wird, werden mehr Abschnitte mit negativer Steigung aussortiert. Die Streuung innerhalb der einzelnen Gruppen ist auf die Abbildung des gesamten Geschwindigkeitsbereichs auf einzelne Steigungswerte zurückzuführen.

Der Steigungswiderstand über der Steigung aus den Datenpunkten der Messstraßenbahn wird durch die grüne Regressionsgerade dargestellt. Die orangene Gerade zeigt den Steigungswiderstand nach Gleichung 2-15. Für den theoretischen Steigungswiderstand wird ein mittel ausgelastetes Fahrzeug sowie ein konstanter Laufwiderstand angenommen.

Die grafische Übereinstimmung zwischen dem ermittelten Steigungswiderstand der Messstraßenbahn und dem theoretisch erwarteten Verlauf ist hoch. Bei betragsmäßig hohen Steigungen wird der Absolutwert des Steigungswiderstands aus der Theorie leicht unterschätzt. Diese Diskrepanzen können auf Abweichungen im Laufwiderstand und in den Passagierzahlen, welche nur auf Statistiken beruhen, zurückzuführen sein.

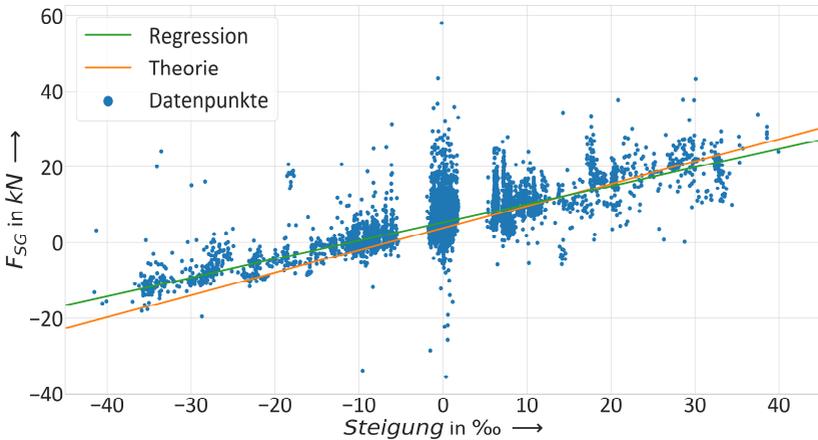


Abbildung 4.7: Analyse des Steigungswiderstands der Messstraßenbahn inklusive einer Regressionsfunktion durch die Datenpunkte und einem theoretischen Verlauf nach Gleichung 2-15

Bogenwiderstand

Für die Analyse des Bogenwiderstands werden 19 verschiedene Kurven mit einem durchschnittlichen Radius kleiner 300 Meter im Karlsruher Stadtbahnnetz untersucht. Die verschiedenen Fahrten und der daraus ermittelte Bogenwiderstand der Messstraßenbahn sind in Abbildung 4.8 dargestellt. Dabei befinden sich sämtliche betrachtete Kurven auf ebener Strecke. In grün dargestellt ist die Regressionskurve zum Bogenwiderstand durch Fahrten der Messstraßenbahn. Zudem sind in orange die Literaturwerte für den jeweiligen Bogenradius nach Ihme [104] durch Gleichung 2-16 abgebildet.

Vom grundsätzlichen Verlauf stimmen beide Kurven in hohem Maße überein. Dennoch ist die Streuung der Messpunkte hoch, trotz teils ähnlicher Bogenradien. Dies ist bedingt durch die Bestimmung der Trägheitskraft nach Gleichung 4-2a. Gerade in Kurven mit geringen Radien wird durch den Spurkranz-anlauf die Geschwindigkeit verringert, was in einem erhöhten Wert der Trägheitskraft resultiert.

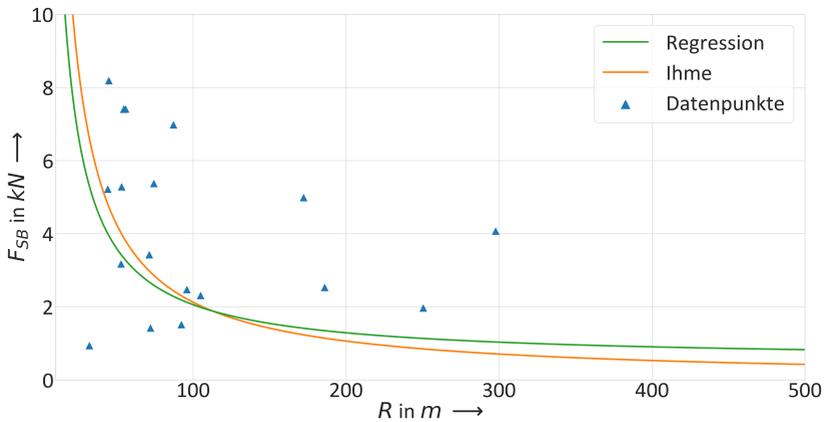


Abbildung 4.8: Analyse des Bogenwiderstands der Messstraßenbahn inklusive einer Regressionsfunktion durch die Datenpunkte und Literaturwerte

4.2.5 Interpretation und Evaluation

Die Ergebnisse von Laufwiderstand, Steigungswiderstand und Bogenwiderstand zeigen, dass die Werte mit denen der Literatur und der Theorie übereinstimmen. Die Aggregation der Höhen- und Steigungsdaten sowie der Kurvenradien ist demnach von hoher Qualität. Die erzeugte Datengrundlage kann für die datengetriebene Modellierung des gesamten Bahnsystems verwendet werden.

4.3 Klassifikation der Fahrphasen

Auf Basis der Datengrundlage sind erste Untersuchungen zum Fahrverhalten und den damit verbundenen Einflüssen auf Energiebedarf und Pünktlichkeit möglich. Aus den Abbildungen 3.1 und 3.2 folgt, dass die Energieeffizienz zwar durch gezieltes Coasting erhöht werden kann, sich dadurch jedoch die Fahrzeit verlängert. Der Coasting-Anteil in jedem Streckenabschnitt stellt eine

zentrale Kennzahl zur Energieeffizienz und zur Pünktlichkeit dar. Diese Kennzahl kann im weiteren Verlauf der Dissertation genutzt werden, um die Fahrweise zwischen Fahrer und KI zu vergleichen. Im Folgenden wird das Vorgehen zur automatisierten Klassifikation der Fahrweise detailliert und erste Ergebnisse auf einem ausgewählten Abschnitt der Linie 4 veranschaulicht.

4.3.1 Vorgehen Klassifikation

Die Klassifikation des Fahrverhaltens kann über die Fahrhebelstellung des Fahrers durchgeführt werden. Diese Messgröße ist jedoch erst seit der Systemerweiterung Ende 2020 durch den Zugriff auf den sicherheitsrelevanten Fahrzeugbus verfügbar. Des Weiteren verwendet auch die KI nicht die Fahrhebelstellung als Input für die gewählte Geschwindigkeitstrajektorie. Aus diesem Grund wird ein zweistufiges Verfahren gewählt. Zunächst wird ein regelbasierter Klassifikator nach [217] auf ausgewählten Tagen mit einer bekannten Fahrhebelstellung trainiert. Anschließend werden weitere Klassifikatoren ohne Kenntnis der Fahrhebelstellung trainiert. Dieses Training wird mit Datensätzen durchgeführt, die ebenfalls eine Fahrhebelstellung zur Verfügung haben, wodurch die Klassifikatoren evaluiert werden können. Das Vorgehen ist abgeleitet aus Scherm [183].

Regelbasierte Klassifikation mit Fahrhebeldaten

Die Fahrphasen der regelbasierten Klassifikation sind aus der Fahrhebelstellung (FHS) und der Längsbeschleunigung des Fahrzeugs abgeleitet. Der Fahrhebel des Messfahrzeugs kann Stellungen zwischen -100 (maximale Verzögerung) und 100 (maximale Beschleunigung) einnehmen. In der Stellung 0 wird keine Zug- oder Bremskraftanforderung durch den Fahrer gestellt. Die Fahrphasen der regelbasierten Klassifikation werden nach Tabelle 4.3 zugeordnet. Der Toleranzwert $a_{cruising}$, bis zu welchem noch eine Beharrungsfahrt erkannt wird, kann vom Nutzer eingestellt werden. Dieser Grenzwert wird in dieser Dissertation auf eine betragsmäßige Beschleunigung von bis zu $0,1 \text{ m/s}^2$ festgelegt.

Tabelle 4.3: Regelbasierte Klassifikation der Fahrphasen mittels der Fahrhebelstellung und der Längsbeschleunigung des Fahrzeugs

Fahrphase	Längsbeschleunigung	Fahrhebelstellung
Cruising	$ a \leq 0,1 \text{ m/s}^2$	Keine Auswirkung
Beschleunigung	$a > a_{\text{cruising}}$	$FHS > 0$
Verzögerung	$a < -a_{\text{cruising}}$	$FHS < 0$
Coasting	Keine Auswirkung	$FHS = 0$

Anhand dieser Zuordnungsvorschrift wird für jeden Datenpunkt des Datensatzes eine Klassifikation durchgeführt. Zudem wird sichergestellt, dass jeder Datenpunkt eineindeutig einer Fahrphase zugeordnet wird. Im Anschluss an die Klassifikation wird ein Postprocessing durchgeführt, das Fahrphasen zusammenfasst, insofern diese kürzer als eine festgelegte Mindestlänge sind. Diese Mindestlänge einer erkannten Fahrphase beträgt 10 Meter. Dadurch wird eine zu starke Fragmentierung der erkannten Fahrphasen und die Fehlklassifikation in Übergangsbereichen zwischen Fahren und Bremsen verhindert.

Die Klassifikation mit Fahrhebeldaten wird im weiteren Verlauf zur Evaluation der Klassifikation ohne Fahrhebeldaten als Ground Truth verwendet.

Klassifikation ohne Fahrhebeldaten

Die Klassifikation der Fahrphasen soll auch ohne die Kenntnis der genauen Sollwertgeberstellung des Fahrers rekonstruiert werden können. Dies wird anhand mehrerer Betriebstage evaluiert, welche ebenfalls über Fahrhebeldaten verfügen. Dadurch kann ein Vergleich hinsichtlich der ermittelten Fahrphasen durchgeführt werden.

Auf den Datensätzen dieser Betriebstage werden drei verschiedene Klassifikationsverfahren trainiert. Diese nutzen zur Klassifikation der Fahrphasen die Längsbeschleunigung und die Traktionsleistung des Fahrzeugs. Verglichen

werden ein regelbasierter Klassifikationsansatz sowie die in Kapitel 2.1 beschriebenen Verfahren des Decision Trees und des Random Forests. Die Erkennung der Fahrphasen FP durch den regelbasierten Klassifikator erfolgt durch Gleichung 4-4. Der Grenzwert für erkanntes Cruising $a_{Cruising}$ wird hier ebenfalls auf eine Längsbeschleunigung von $0,1 \text{ m/s}^2$ festgelegt. Die Grenze der Traktionsleistung $|p_{Traktion}|$ zur Erkennung von Coasting liegt bei $p_{Coasting} = 15 \text{ kW}$. Beide Grenzwerte können vom Nutzer festgelegt werden.

$$FP(a, p) = \begin{cases} \text{Beschleunigung} & , a > a_{Cruising} \\ \text{Verzögerung} & , a < -a_{Cruising} \\ \text{Cruising} & , |a| \leq a_{Cruising} \\ \text{Coasting} & , |p_{Traktion}| \leq p_{Coasting} \end{cases} \quad (4-4)$$

Decision Tree und Random Forest erhalten als Input die Fahrzeuggeschwindigkeit, die Längsbeschleunigung sowie die Traktionsleistung.

Vergleich Klassifikationsverfahren

In Tabelle 4.4 sind die Ergebnisse der drei Klassifikationsverfahren für einen gesamten Betriebstag mit mehr als 300.000 Datenpunkten dargestellt. Im Vergleich zur regelbasierten Klassifikation mit den Fahrhebeldaten weisen alle Klassifikatoren Übereinstimmungen von mehr als 90 % auf. Der Random Forest-Klassifikator zeigt mit 96 % die beste Übereinstimmung und wird daher für die weitere Dissertation genutzt.

Tabelle 4.4: Vergleich der Übereinstimmung der drei Klassifikationsverfahren mit der regelbasierten Klassifikation anhand der Fahrhebeldaten

	Klassifikationsverfahren		
	Regelbasierte Klassifikation	Decision Tree	Random Forest
Übereinstimmung mit Ground Truth	90 %	95 %	96 %

4.3.2 Ergebnisse der Klassifikation der Fahrphasen

Abbildung 4.9 zeigt die Ergebnisse der Klassifikation der Fahrphasen auf einem beispielhaften Abschnitt der Linie S1 mit dem trainierten Random Forest Klassifikator. Der Haltestellenabschnitt ist eben und weist keine signifikanten Bogenradien auf. Dadurch ist eine Fehlklassifikation durch Wechselwirkungen mit der Infrastruktur ausgeschlossen.

Jede Fahrphase wurde im Abschnitt mindestens einmal klassifiziert. Am häufigsten werden die Phasen Beschleunigung und Coasting erkannt. In Bezug auf die dargestellte Geschwindigkeitstrajektorie sowie die theoretischen Grundlagen zu den Fahrphasen aus Kapitel 3.1 ist das Klassifikationsergebnis sehr gut.

Bei der Klassifikation aller Fahrten auf dem exemplarischen Streckenabschnitt zwischen der Haltestelle Im Eichbäumle und der Glogauer Straße resultiert eine Verteilung nach Abbildung 4.10. Der Haltestellenabschnitt verfügt über eine eigene Trasse ohne Interaktionen mit dem Individualverkehr. Lediglich die Fahrweise der Fahrer und die zugrundeliegende betriebliche Situation sind ausschlaggebend für Energieeffizienz und Pünktlichkeit.

Abbildung 4.10 (a) zeigt den jeweiligen Energiebedarf über die gefahrene Zeit auf dem Streckenabschnitt. Farblich hinterlegt ist für jede einzelne Fahrt der klassifizierte Coasting-Anteil mit dem Random Forest-Klassifikator. Abbildung 4.10 (b) zeigt den Energiebedarf über den klassifizierten Coasting-Anteil auf.

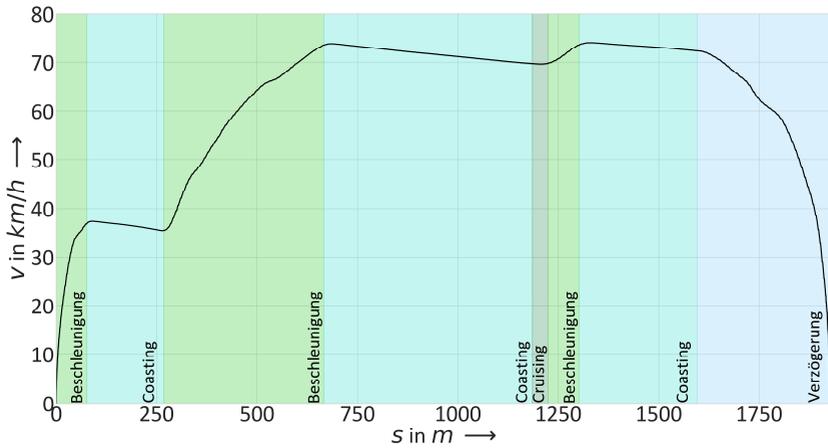


Abbildung 4.9: Klassifikation der Fahrphasen auf einem einzelnen Streckenabschnitt zwischen der Welschneureuter Straße und dem Haus Bethlehem auf der Linie S1/S11

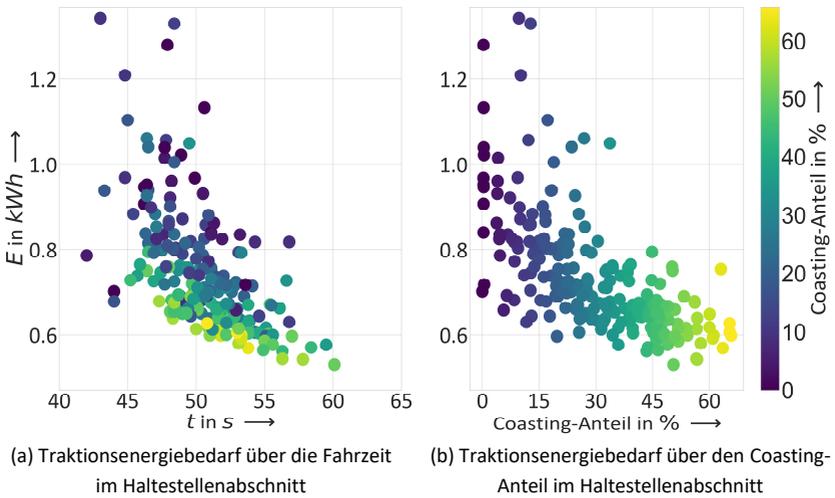


Abbildung 4.10: Klassifikation aller Fahrten auf dem Streckenabschnitt Im Eichbäumle bis Waldstadt Glogauer Straße

Vermehrtes Coasting führt zu einer besseren Energieeffizienz. Ein höherer Coasting-Anteil resultiert jedoch wiederum in einer Verlängerung der Fahrzeit. Diese Art der Analyse wird ebenfalls beim Vergleich der Fahrprofile von Fahrer und KI im späteren Verlauf der Dissertation hinzugezogen.

5 Modellierung Deep Reinforcement Learning-System

Das fünfte Kapitel umfasst den Aufbau des gesamten Deep Reinforcement Learning-Systems (vgl. Abbildung 5.1), in welchem im weiteren Verlauf die KI trainiert wird. Aufbauend auf der Datengrundlage der Karlsruher Messstraßenbahn wird ein Umgebungsmodell bestehend aus dem Fahrzeug-, dem Betriebs- und dem Infrastrukturmodell aufgebaut. Des Weiteren wird festgelegt, mit welchen Aktionen der Agent mit der Umgebung interagieren kann und anhand welcher Zustände er Rückmeldungen aus der Umgebung erhält. Anschließend wird die Belohnungsfunktion definiert, mit welcher der Agent das gewünschte Verhalten einer energieeffizienten und pünktlichen Fahrtrajektorie erlernt. Im letzten Schritt wird der Algorithmus parametrisiert.

Durch die Datengrundlage der Karlsruher Messstraßenbahn können sämtliche Modelle validiert werden. Mittels der validierten Umgebung können die Fahrprofile, welche von der KI errechnet werden, mit denen der Fahrer aus dem regulären Fahrgastbetrieb verglichen werden.

Die Modellierung der Umgebung wird in der Python-Bibliothek OpenAI durchgeführt. Dabei handelt es sich um eine Open Source-Bibliothek, welche zum Training und zum Test von Deep-RL-Agenten eingesetzt wird. [25] Darüber hinaus sollen alle weiteren Berechnungen ebenfalls in Python durchgeführt werden. Dadurch kann zusätzlicher Berechnungs- und Verarbeitungsaufwand durch Co-Simulationen vermieden werden.

Sämtliche Berechnungen werden auf einem System mit einem Intel i7 12700K Prozessor durchgeführt. Zur Beschleunigung des Trainings der Neuronalen Netze ist im System eine Nvidia Grafikkarte vom Typ GeForce GTX 3090 mit einem Grafikspeicher von 24 GB verbaut. Das Training der Neuronalen Netze erfolgt mit der Tensorflow-Version 2.4.0 [205].

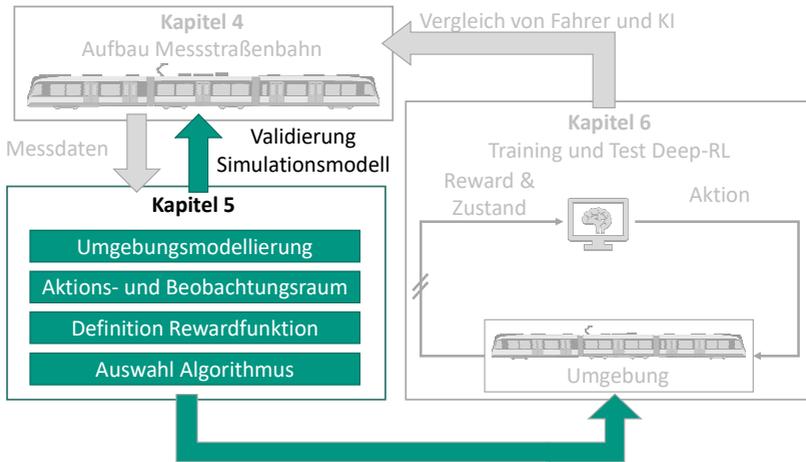


Abbildung 5.1: Einordnung des fünften Kapitels in den Lösungsansatz

5.1 Fahrzeugmodellierung

Das Umgebungsmodell des Deep Reinforcement Learning Systems setzt sich aus dem Fahrzeugmodell sowie dem Infrastruktur- und Betriebsmodell zusammen. Durch Interaktion mit dieser Umgebung erlernt die KI energieeffiziente und pünktliche Fahrtrajektorien.

5.1.1 Einordnung der Modellierung des Energiebedarfs in den Stand der Technik und Wissenschaft

Der Energiebedarf von Schienenfahrzeugen kann auf verschiedene Arten berechnet werden. Das Ergebnis der Energiebedarfsmodellierung wird durch die Modellierungstiefe und der Art des Modellierungsinputs beeinflusst. In der Literatur wird zwischen drei Ansätzen der Modellierungstiefe unterschieden. Der White-Box-Ansatz modelliert die einzelnen Systemkomponenten detailliert auf der Basis physikalischer Berechnungen. Black-Box-Modelle arbeiten

rein datenbasiert und erlauben eine implizite Modellierung der betriebspunktabhängigen Wirkungsgrade der einzelnen Komponenten auf Systemebene. Gray-Box-Modelle stellen eine Mischform dar, bei denen grundlegende physikalische Zusammenhänge weiterhin abgebildet werden. Einzelne Komponenten werden jedoch datenbasiert beispielsweise durch Wirkungsgradkennfelder dargestellt. [119] Eine weitere Unterscheidung von Energiebedarfsmodellen kann anhand der Modellierungsinputs vorgenommen werden. Dabei wird zwischen mikroskopischen, mesoskopischen und makroskopischen Modellierungsinputs unterschieden. Mikroskopische Modelle berechnen für jeden Zeitschritt explizit den Energiebedarf. Makroskopische Modelle aggregieren Daten über ein räumliches und zeitliches Intervall und berechnen daraus Durchschnittswerte für den Energiebedarf. Mesoskopische Modelle aggregieren wie makroskopische Modelle die Inputdaten, führen jedoch exakte Energiebedarfsberechnungen durch. [65]

Chen gibt einen Überblick über verschiedene Ansätze und Kombinationen von Modellierungstiefen und Modellierungsinputs [34]. Auf Systemebene kommen White-Box-Ansätze aufgrund der hohen Rechenzeiten äußerst selten zum Einsatz. Gray-Box-Ansätze kombiniert mit einem mikroskopischen Modellierungsinput finden die häufigste Anwendung. Die Berechnung des Energiebedarfs basiert entweder auf einer reinen Fahrwiderstandsberechnung [38, 71, 80, 120], oder einer Berechnung mit Wirkungsgradkennfelder einzelner Systemkomponenten des Antriebsstrangs [146, 169]. Black-Box-Ansätze werden in Kombination mit mikroskopischen, mesoskopischen und makroskopischen Modellierungsinputs verwendet. Rhode untersucht die mikroskopische Modellierung des Energiebedarfs eines elektrischen PKW mittels adaptiver Kernel-Filter und Neuronaler Netze [173]. Pineda-Jaramillo untersucht verschiedene Verfahren des Maschinellen Lernens zur Prädiktion des Energiebedarfs von Metrofahrzeugen [161]. Bei mesoskopischen Modellierungsinputs werden Neuronale Netze [139, 215] und Kalman-Filter [196] eingesetzt. Eine makroskopische Modellierung wird ebenfalls mit Neuronalen Netzen durchgeführt [70, 198].

Am Institut für Fahrzeugsystemtechnik wird bereits ein Multi-Physik-Simulationsmodell (MPS) zur Berechnung des Energiebedarfs von Schienenfahrzeugen verwendet. Dieses basiert auf einem mikroskopischen Gray-Box-Ansatz und modelliert die Systemkomponenten des elektrischen Antriebsstrangs mit Wirkungsgradkennfeldern. Das Fahrzeugmodell besteht aus einem Steuerungssystem, dem Antriebssystem, einem Modell der Fahrwiderstände sowie einem Infrastrukturmodell. Das Antriebssystem wird durch eine Sollwertvorgabe der Zugkraft durch das Steuerungssystem angesteuert. Vom Antriebssystem werden die aktuelle Geschwindigkeit des Fahrzeugs an das Steuerungsmodell zurückgemeldet. Das Infrastrukturmodell übergibt die aktuelle Steigung und den Kurvenradius an das Fahrwiderstandsmodell. Mit den Wirkungsgraden der einzelnen Komponente des Antriebsstrangs kann damit in jedem Zeitschritt der momentane Leistungsbedarf berechnet werden. [170] Modelliert wird dieses Fahrzeugmodell mit der Software Dymola [42]. Bisher wird das Fahrzeugmodell zur Betriebsstrategieoptimierung von Batteriefahrzeugen eingesetzt [59]. Vorteilhaft bei MPS ist die Möglichkeit, das Modell für neue Fahrzeuge zu parametrieren. In [170] wird die Anpassung und Parametrierung des MPS für das Fahrzeug NET 2012 (vgl. Tabelle 4.1) durchgeführt. Die Wirkungsgradkennfelder des elektrischen Antriebsstrangs werden durch die Energiebedarfsmessungen der Karlsruher Messstraßenbahn ermittelt [170].

5.1.2 Vorgehensweise

Zur Validierung der Modellierung und um Vergleiche zwischen den simulierten und realen Fahrprofilen durchzuführen, ist eine Kalkulation des Energiebedarfs durch Fahrwiderstandsberechnungen nicht ausreichend. Der Antriebsstrang des Schienenfahrzeugs beinhaltet mit den elektrischen Antrieben, der Leistungselektronik und den Getriebenen Komponenten, die betriebspunktabhängige Verluste aufweisen. Für diese stehen keine Kennfelder zur Verfügung, anhand derer die Verluste in Abhängigkeit der Drehzahl und des Drehmoments dargestellt werden können. Aus dem Projekt der Karlsruhe-

her Messstraßenbahn steht jedoch eine Datengrundlage aus Langzeitmessungen zur Verfügung, welche zur Modellierung des Energiebedarfs verwendet werden kann.

Durch eine Black-Box-Modellierung können die Rechenzeiten gegenüber den weiteren Modellierungsansätzen reduziert werden. Eine geringe Berechnungsdauer ermöglicht im späteren Verlauf mehr Trainingsdurchläufe der KI. Auf Basis der Datengrundlage aus dem Betrieb der Messstraßenbahn kann mittels einer datengetriebenen Modellierung eine hohe Genauigkeit erreicht werden. Diese hohe Genauigkeit ist bedingt durch die implizite Modellierung von Zusammenhängen innerhalb des Antriebsstrangs, welche in einer physikalischen Modellierung zumeist nicht vollumfänglich berücksichtigt werden können.

Für die Black-Box-Modellierung eignen sich sowohl mikroskopische als auch mesoskopische Modellierungsinputs, da exakte Ergebnisse und keine Durchschnittswerte angestrebt werden. Die Modellierung ist angelehnt an Tesar [207]. Als Datenbasis stehen 8859 Haltestellenintervalle mit mehr als 7,5 Millionen Datenpunkten auf sieben verschiedenen Linien seit Mai 2019 aus dem Betrieb der Messstraßenbahn zur Verfügung. In den ausgewählten Haltestellenabschnitten treten keine Verluste im Bremswiderstand auf. Als Evaluationsdatensatz werden weitere 617 Haltestellenintervalle zurückgehalten, welche nicht in den Trainings- und Testdaten enthalten sind. Da sich die Modellierungsinputs von mikroskopischen und mesoskopischen Modellen unterscheiden, kann kein einheitlicher Vergleich der Fehlermaße aus dem Training der Neuronalen Netze vorgenommen werden. Daher werden die trainierten Modelle auf dem Evaluationsdatensatz ausgewertet und miteinander verglichen. Der Evaluationsdatensatz ist aufgrund der Verteilung der befahrenen Linien repräsentativ zur restlichen Datenbasis. [207]

Die Inputs zur Energiebedarfsmodellierung von Schienenfahrzeugen sind durch die DIN 50591 gegeben [47]. Erforderlich zur Berechnung sind die Fahrzeuggeschwindigkeit, die Längsbeschleunigung, die Passagierzahl, der Kur-

venradius sowie die Steigung. Sämtliche Parameter sind in der Datengrundlage aus der Messstraßenbahn enthalten. Die Längsbeschleunigung kann zudem nach Hilmer aus der Fahrzeuggeschwindigkeit abgeleitet werden [92]. Die Beschleunigungssensoren auf dem Fahrzeug weisen mit 2,4 kHz (vgl. Kapitel 4.1.2) eine wesentlich höhere Abtastrate als die weiteren Messgrößen auf. Die Verwendung dieser Rohdaten würde in einem aufwändigeren Pre-processing resultieren und das Ergebnis nicht weiter verbessern.

Einen Überblick über die möglichen Architekturen zur Modellierung des Energiebedarfs gibt Abbildung 5.2. Der Input zur mikroskopischen Modellierung basiert auf den aufgezeichneten Messdaten und berechnet den aktuellen Leistungs- und Energiebedarf zu jedem Zeitschritt. LSTM, MLP und CNN (vgl. Kapitel 2.1.3) sind daher geeignete Modellarchitekturen für die mikroskopische Modellierung. Der Input zur mesoskopischen Modellierung hat den Vorteil, dass er robuster gegenüber Abweichungen einzelner Messwerte ist. Des Weiteren bestehen Vorteile in der Berechnungszeit, da nur eine einzige Transformation der Eingangsdaten und nur eine Prädiktion über ein Haltestellenintervall durchgeführt wird. Die Transformation der Eingangsdaten ist notwendig, damit konstante Eingangssensoren durch das Neuronale Netz propagiert werden, unabhängig von der Länge des Streckenabschnitts. Durch diese Transformation ist eine sequentielle Verarbeitung der Daten nicht mehr möglich, weswegen LSTM nicht für den mesoskopischen Ansatz verwendet werden können. [207]

Die Mindestabtastfrequenz zur Ermittlung des Energiebedarfs ist nach DIN 50591 auf 1 Hz festgelegt [47]. Die mit 10 Hz aufgezeichneten Messdaten werden auf 5 Hz, 2 Hz und 1 Hz heruntergesampelt, um die Auswirkungen der Abtastrate auf die Prädiktionsqualität zu untersuchen. Niedrigere Abtastfrequenzen können im späteren Verlauf zu einer schnelleren Konvergenz bei der Anwendung des Modells zum Training der KI führen, da die Deep-RL-Umgebung ebenfalls mit einer niedrigeren Frequenz arbeiten kann. Dies setzt jedoch voraus, dass auch bei geringeren Abtastraten die Prädiktion noch immer

eine hohe Genauigkeit aufweist. Durch diesen Zusammenhang ist die Genauigkeit nicht das alleinige Zielkriterium der Energiebedarfsprädiktion, sondern es ist erforderlich, eine Abwägung zwischen Abtastfrequenz, Genauigkeit und Rechenzeit der Modelle zu treffen.

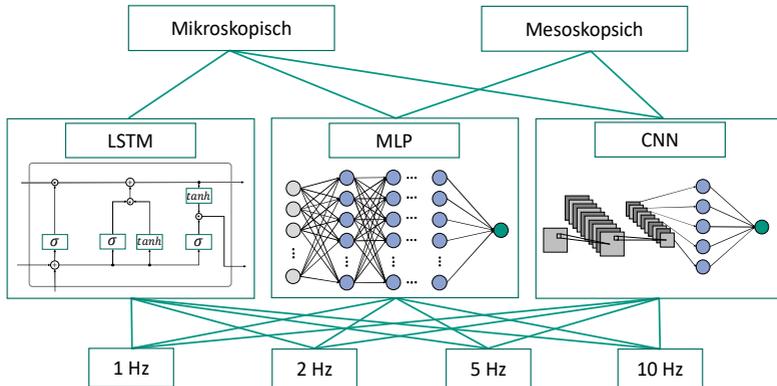


Abbildung 5.2: Übersicht über die verschiedenen Modellierungsarten und Abtastfrequenzen zur Prädiktion des Energiebedarfs mit Black-Box-Modellen nach Tesar [207]

Zum Vergleich der Ergebnisse der verschiedenen Modelle werden Fehlermaße verwendet. Die Schätzung des Energiebedarfs zwischen zwei Haltestellen wird mittels des Korrelationskoeffizienten r und dem Mean Absolute Percentage Error (MAPE) durchgeführt. Der MAPE berechnet die prozentuale Abweichung des prädizierten und des gemessenen Energiebedarfs.

Für die mikroskopische Modellierung wird zudem eine Fitness-Funktion nach Gleichung 5-1 hinzugezogen. Diese Funktion berechnet in jedem Zeitschritt den Root Mean Square Error (RMSE) zwischen der gemessenen und prädizierten Leistung. Der RMSE wird über die Spannbreite der minimal gemessenen Leistung y_{min} und der maximal gemessenen Leistung y_{max} normiert. Durch diese Normierung kann das Ergebnis der Prädiktion mit weiteren Forschungsarbeiten unabhängig vom Anwendungsfall Straßenbahn verglichen werden. [207]

$$Fitness = 100 \cdot \left(1 - \frac{RMSE}{y_{max} - y_{min}} \right) \quad (5-1)$$

Des Weiteren werden die Modelle mit dem am Institut für Fahrzeugsystemtechnik erstellten Multi-Physik-Simulationsmodell verglichen.

Mikroskopische Modellierung

Zur mikroskopischen Modellierung werden die vorverarbeiteten Daten für jeden Zeitschritt durch das Neuronale Netz propagiert. Die Inputs und der Output werden auf den Wertebereich $[0, 1]$ normiert, um den Lernprozess der Neuronalen Netze zu beschleunigen. Tabelle 5.1 zeigt die für die mikroskopische Modellierung festgelegten Hyperparameter (vgl. Kapitel 2.1.3.4). Für das Training sind insgesamt 40 Epochen sowie die Batch-Size von 1024 vorgesehen. Die Lernrate η wird zu 0,001 mit einer intelligenten und adaptiven Anpassung durch die Adam Optimierung (vgl. Kapitel 2.1.3.4) festgelegt. Damit wird das Gradientenabstiegsverfahren zur Anpassung der Neuronengewichte bei verbesserter Konvergenz beschleunigt. [207]

Zur weiteren Beschleunigung des Trainings und zur Vermeidung von Overfitting wird mit Early Stopping eine Regularisierungstechnik (vgl. Kapitel 2.1.3.4) eingesetzt. Sollte es in 13 Epochen zu keiner Verbesserung der Prädiktion auf dem Testdatensatz kommen, wird der Trainingsvorgang abgebrochen. Der gesamte Datensatz wird in einen Trainings- und Testdatensatz unterteilt. Dafür werden 65 % der Daten zum Training und 35 % zum anschließenden Test genutzt.

Tabelle 5.1: Festgelegte Hyperparameter für das Training mikroskopischer Modelle

Hyperparameter	Wert
Epochen	40
Batch-Size	1024
Lernrate	0,001 (Adam-Optimierung)
Early Stopping	13 Epochen
Unterteilung Trainings- und Testdaten	65 % Training 35 % Test

Die Architektur der Neuronalen Netze beeinflusst ebenfalls die Prädiktionsqualität. Um eine Architektur zu identifizieren, die den Energiebedarf bestmöglich prädiziert, wird eine Grid Search in Form einer vollfaktoriellen Versuchsplanung durchgeführt. Die zu variierenden Hyperparameter für MLP bei der mikroskopischen Modellierung sind in Tabelle 5.2 aufgeführt. Die Anzahl der vollvernetzten Schichten (VVN) (vgl. Kapitel 2.1.3.1) wird zwischen 1 und 4 variiert, die Anzahl der Neuronen in Zehnerschritten von 10 bis 200. Zudem wird mit Dropout (vgl. Kapitel 2.1.3.4) eine weitere Regularisierungstechnik eingesetzt. Durch Dropout wird je Schicht eine festgelegte prozentuale Anzahl an Neuronen abgeschaltet. Dadurch wird die Modellgröße reduziert und es wird Overfitting entgegengewirkt.

Tabelle 5.2: Variable Hyperparameter der Grid Search für mikroskopische MLP

Hyperparameter	Wert
Anzahl vollverbundener Schichten	1, 2, 3, 4
Anzahl Neuronen	10, 20, 30, 40, ..., 200
Dropout	0 %, 5 %, 10 %

Tabelle 5.3 zeigt die zu variierenden Hyperparameter für mikroskopische CNN. Neben der Variation der vollvernetzten Schichten wird hier zusätzlich die Anzahl der Faltungsschichten (FS) (vgl. Kapitel 2.1.3.2) variiert. Zudem

werden auch für CNN die Anzahl an Neuronen in den vollvernetzten Schichten sowie Dropout variiert.

Tabelle 5.3: Variable Hyperparameter der Grid Search für mikroskopische CNN

Hyperparameter	Wert
Anzahl Faltungsschichten	1, 2, 3
Anzahl vollverbundener Schichten	1, 2
Anzahl Neuronen	10, 20, 30, 40, ..., 200
Dropout	0 %, 5 %, 10 %

In Tabelle 5.4 sind die variablen Hyperparameter für mikroskopische LSTM aufgelistet. Auch für LSTM wird die Anzahl vollverbundener Schichten sowie zusätzlich die Anzahl an LSTM-Schichten (vgl. Kapitel 2.1.3.3) variiert. Adäquat zu MLP und CNN werden ebenfalls die Anzahl der Neuronen und Dropout variiert. Zusätzlich wird bei LSTM festgelegt, wie viele vergangene Werte der Zeitreihe in das Modell einfließen. Hierfür wurde vorab eine Variation zwischen zwei und sieben Werten durchgeführt, wobei mit drei Zeitschritten die besten Ergebnisse erzielt wurden.

Tabelle 5.4: Variable Hyperparameter der Grid Search für mikroskopische LSTM

Hyperparameter	Wert
Anzahl LSTM-Schichten	1, 2, 3
Anzahl vollverbundener Schichten	1, 2
Anzahl Neuronen	10, 20, 30, 40, ..., 200
Dropout	0 %, 5 %, 10 %

Mesoskopische Modellierung

Bei der mesoskopischen Modellierung werden einzelne Haltestellenintervalle in eine Histogrammdarstellung überführt. Diese Modellierung ist angelehnt an Topić [215], wobei Topić lediglich Histogramme aus der Fahrzeuggeschwindigkeit sowie der Längsbeschleunigung erstellt. Dieser Ansatz wird in dieser Dissertation um die zwei Dimensionen Steigung und Kurvenradius erweitert, wodurch ein vierdimensionales Histogramm entsteht. Die Anzahl der Passagiere ist in einem Haltestellenintervall konstant und wird daher nicht in das Histogramm aufgenommen, um die Anzahl der Dimensionen und damit den Speicherbedarf zu reduzieren. Die Passagierzahl wird erst in einem späteren Schritt in das Neuronale Netz eingespeist. Dadurch ergibt sich eine Netzwerkarchitektur nach Abbildung 5.3. Zunächst werden die Eingangsgrößen für die Histogramme auf den Wertebereich $[0, 1]$ normiert. Anschließend werden die Histogramme durch Neuronale Netze mit einer festgelegten Anzahl von m Schichten verarbeitet. Diese Schichten können sowohl vollvernetzte Schichten als auch Faltungsschichten sein. Im Folgenden wird der Output durch eine Flatten-Schicht in einen eindimensionalen Vektor überführt. Zu diesem Vektor wird über eine Concatenate-Schicht die normierte Passagierzahl im Haltestellenintervall hinzugefügt. Dieser daraus resultierende Tensor wird anschließend durch weitere n vollvernetzte Schichten von Neuronalen Netzen propagiert. Das Endergebnis stellt der prädierte Energiebedarf für das jeweilige Haltestellenintervall dar. [207]

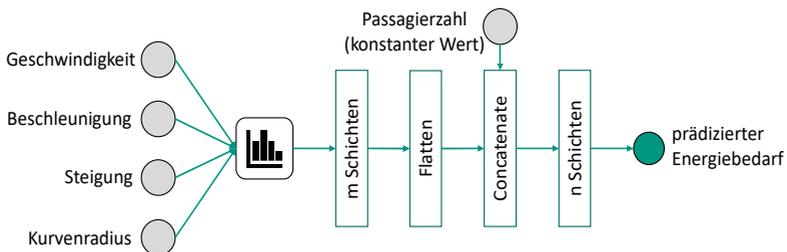


Abbildung 5.3: Struktur und Verarbeitungsschritte für die mesoskopische Modellierung nach Tesar [207]

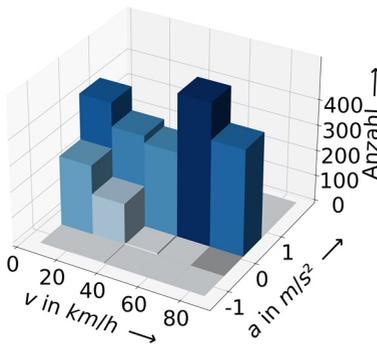
Die Anzahl der Klassen des Histogramms beeinflusst die Prädiktion des Energiebedarfs. Eine zu geringe Anzahl an Klassen resultiert in einer zu starken Aggregation der Datenpunkte, so dass Informationen zum Lernen verloren gehen. Aus einer zu feinen Klassenaufteilung resultieren mehr Datenpunkte, die exakt oder nahe null sind. Dadurch wird die Lernfähigkeit der Neuronalen Netze negativ beeinträchtigt. Insgesamt werden vier verschiedene Klassenaufteilungen der Histogramme untersucht. Die Anzahl der Klassen für Geschwindigkeit, Beschleunigung, Steigung und Kurvenradius wird in Tabelle 5.5 aufgelistet. Nach den Analysen aus Kapitel 4 haben die Fahrzeuggeschwindigkeit, die Längsbeschleunigung und die Steigung den größten Einfluss auf den Energiebedarf. Die Klassenbreite des Histogramms ist für diese Größen gleichverteilt. Kurvenradien treten nur örtlich begrenzt auf und der größte Einfluss ist bei geringen Bogenhalbmessern (vgl. Abbildung 4.8) zu sehen. Um den Speicherplatzbedarf der Histogramme zu reduzieren, werden für den Kurvenradius in allen Histogrammen vier Klassen vorgesehen. Diese sind aufgrund der Einflüsse auf den Fahrwiderstand nichtlinear aufgeteilt mit den Intervallen $[20\text{ m}, 33\text{ m})$, $[33\text{ m}, 50\text{ m})$, $[50\text{ m}, 100\text{ m})$, $[100\text{ m}, 10000\text{ m})$. [207]

Tabelle 5.5: Übersicht über die Klassenanzahl der Histogramme für die einzelnen Merkmale

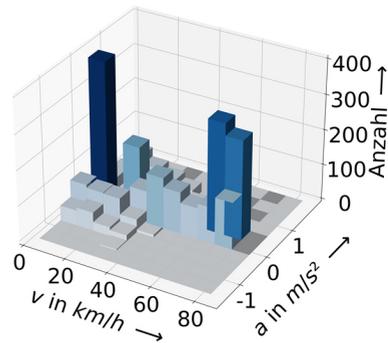
Histogramm	Geschwindigkeit	Beschleunigung	Steigung	Kurvenradius
Histogramm 1	5	5	6	4
Histogramm 2	10	10	11	4
Histogramm 3	20	20	22	4
Histogramm 4	30	30	33	4

Der Einfluss der Klassenaufteilung wird exemplarisch durch die Darstellung eines Fahrzyklus auf der Linie S1/S11 im Abschnitt zwischen der Welschneureter Straße und dem Haus Bethlehem in Abbildung 5.4 verdeutlicht. Aus Gründen der Darstellbarkeit beschränkt sich die Abbildung auf die Fahrzeuggeschwindigkeit sowie die Längsbeschleunigung. Abbildung 5.4 (a) zeigt das

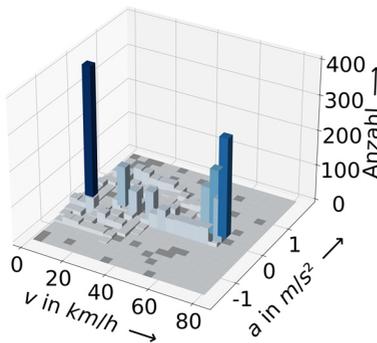
Histogramm für eine Klassenaufteilung von fünf Geschwindigkeits- und Beschleunigungsklassen. Durch die geringere Auflösung kann, im Gegensatz zu den Klassenaufteilungen von Abbildung 5.4 (b) und (c), das Auftreten der Geschwindigkeits- und Beschleunigungskombination weniger genau verortet werden. Bei feineren Auflösungen wie in den Abbildungen 5.4 (c) und (d) nimmt die Anzahl der nicht besetzten Klassen stark zu. Im Zusammenspiel mit Steigungen und Kurvenradien sind noch mehr leere Histogrammklassen zu erwarten, was den Lernprozess der Neuronalen Netze erschwert.



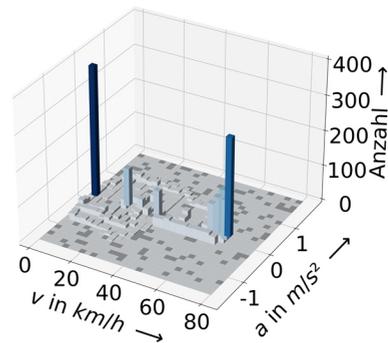
(a) Histogramm mit 5 Klassen



(b) Histogramm mit 10 Klassen



(c) Histogramm mit 20 Klassen



(d) Histogramm mit 30 Klassen

Abbildung 5.4: Auswirkung der Klassenanzahl auf die Verteilung der Datenpunkte der Histogramme

Für das Training der Neuronalen Netze müssen für die mesoskopische Modellierung ebenfalls Hyperparameter festgelegt werden. Diese Parameter sind in Tabelle 5.6 aufgelistet. Aufgrund des hohen Speicherplatzbedarfs der Histogramme muss die Batch Size im Gegensatz zur mikroskopischen Modellierung auf 50 reduziert werden. Die weiteren Parameter sind identisch zur mikroskopischen Modellierung.

Tabelle 5.6: Festgelegte Hyperparameter für das Training mesoskopischer Modelle

Hyperparameter	Wert
Epochen	40
Batch-Size	50
Epochen	0,001 (Adam Optimierung)
Early Stopping	13 Epochen
Unterteilung Trainings- und	65 % Training
Testdaten	35 % Test

Wie bei der mikroskopischen Modellierung wird auch für mesoskopische Modelle eine Grid Search durchgeführt. Die zu variierenden Hyperparameter für MLP sind in Tabelle 5.7 aufgeführt. Nach Abbildung 5.3 wird in die verschiedenen Schichten m und n unterschieden. Aufgrund des höheren Speicherplatzbedarfs insbesondere bei der feinen Klassenauflösung der Histogramme ist die Anzahl der Neuronen im Gegensatz zur mikroskopischen Modellierung reduziert.

Tabelle 5.7: Variable Hyperparameter der Grid Search für mesoskopische MLP

Hyperparameter	Wert
Anzahl vollverbundener Schichten m	1, 2
Anzahl vollverbundener Schichten n	1, 2
Anzahl Neuronen Schicht m	24, 48, 72, 96
Anzahl Neuronen Schicht n	24, 48, 72, 96
Dropout	0 %, 5 %, 10 %

Die variablen Hyperparameter für die mesoskopische Modellierung mit CNN sind in Tabelle 5.8 aufgelistet. Die Eingangsschicht, welche die Histogramme verarbeitet, ist als Faltungsschicht ausgeführt. Die weitere Verarbeitung nach Hinzufügen der Passagierdaten wird mittels vollverbundener Schichten umgesetzt. Im Vergleich zur mikroskopischen Modellierung mit CNN sind die Neuronalen Netze für den mesoskopischen Modellierungsinput aufgrund des Speicherplatzbedarfs kleiner.

Tabelle 5.8: Variable Hyperparameter der Grid Search für mesoskopische CNN

Hyperparameter	Wert
Anzahl Faltungsschichten m	1, 2
Anzahl vollverbundener Schichten n	1, 2
Anzahl Neuronen Schicht n	24, 48, 72, 96
Dropout	0 %, 5 %, 10 %

5.1.3 Modellierungsergebnisse

Mikroskopische Modellierung

Die Ergebnisse der mikroskopischen Modellierung des Traktionsenergiebedarfs zeigt Tabelle 5.9. Für jede Abtastfrequenz und jede Art von Neuronalem

Netz sind die besten Modelle hinsichtlich des MAPE und deren Netzwerkar-chitektur aufgelistet. Verglichen werden die einzelnen Modelle anhand der Durchschnittswerte des Korrelationskoeffizienten r , des MAPE, der Fitness-Funktion sowie der Rechenzeit auf den 617 ungesehenen Haltestelleninter-vallen des Evaluationsdatensatzes. Zudem wird für die mikroskopische Mo-dellierung ein Vergleich zum am Institut erstellten Multi-Physik-Simulations-modell (MPS) durchgeführt, welches ebenfalls mit den Daten der Messstraßenbahn parametrisiert wird.

Mit MLP, CNN und LSTM wird sowohl der Leistungs- als auch der Gesamte-nergiebedarf über ein Haltestellenintervall mit hoher Genauigkeit vorausge-sagt. Der durchschnittliche Fitness-Wert der besten Modelle aus Tabelle 5.9 liegt bei 96,5 % und der durchschnittliche MAPE bei 6,62 %. Dabei zeigt sich, dass trotz anspruchsvolleren Netzwerkar-chitekturen die Vorhersage mit CNN und LSTM nicht zu besseren Ergebnissen als mit MLP führt. MLP haben durch die einfacheren Netzwerkar-chitekturen zudem Vorteile in der Rechenzeit. Die durchschnittliche Berechnungszeit für ein Haltestellenintervall ist bei MLP un-gefähr doppelt so schnell wie die von CNN und um das Fünffache schneller als bei LSTM. [207]

Mit Ausnahme von LSTM führen die niedrigeren Abtastraten nicht zu einer wesentlich schlechteren Vorhersage des Energiebedarfs. Die Korrelationsko-effizienten aller Black-Box-Modelle sind durchweg größer als 0,98. Ab einer Korrelation von größer 0,8 wird von einem starken Zusammenhang gespro-chen [20].

Die Werte der Fitness-Funktion übertreffen mit einem durchschnittlichen Wert von 96,5 % vergleichbare Black-Box-Ansätze aus der Literatur [161, 173]. Die prozentuale Abweichung des ermittelten Energiebedarfs im Vergleich zum Datensatz der Karlsruher Messstraßenbahn beträgt im Durchschnitt 6,62 %. [207]

Im Gegensatz zum MPS präzisieren die Neuronalen Netze sowohl den Ener-giebedarf als auch den momentanen Leistungsbedarf besser und haben deut-

liche Vorteile in der Rechenzeit. Beispielsweise kann bei einer Verwendung des 1 Hz MLP-Modells die Berechnungsdauer um mehr als den Faktor 230 reduziert werden. [170]

Tabelle 5.9: Architektur und Ergebnisse der mikroskopischen Modellierung des Energiebedarfs sowie Vergleich mit Multi-Physik-Simulationsmodell nach Tesar [207]

Mikroskopisch	Architektur			Ergebnisse			
	Schichten	Neuronen	Dropout	r	MAPE	Fitness	Rechenzeit / s
MLP 1Hz	2 VVN	180	0	0,985	6,74 %	96,61 %	0,06
MLP 2 Hz	2 VVN	160	0	0,984	6,27 %	96,78 %	0,13
MLP 5 Hz	2 VVN	110	0	0,984	6,58 %	96,87 %	0,31
MLP 10 Hz	2 VVN	120	5 %	0,988	5,82 %	97,10 %	0,69
CNN 1 Hz	1 FS, 2 VVN	100	5 %	0,982	7,03 %	96,62 %	0,12
CNN 2 Hz	1 FS, 2 VVN	70	0	0,984	6,54 %	96,71 %	0,23
CNN 5 Hz	1 FS, 2 VVN	140	5 %	0,983	6,45 %	96,85 %	0,58
CNN 10 Hz	1 FS, 2 VVN	190	0	0,988	6,04 %	96,90 %	1,16
LSTM 1 Hz	1 LSTM, 2 VVN	110	10 %	0,981	8,60 %	93,76 %	0,31
LSTM 2 Hz	1 LSTM, 2 VVN	170	0	0,984	7,17 %	96,15 %	0,62
LSTM 5 Hz	1 LSTM, 2 VVN	100	0	0,983	6,42 %	96,76 %	1,51
LSTM 10 Hz	3 LSTM, 1 VVN	200	0	0,988	5,79 %	96,81 %	3,63
MPS	-	-	-	0,977	8,74 %	94,53 %	14,02

Die Abbildungen 5.5 bis 5.8 zeigen die Prädiktion der Traktionsleistung der verschiedenen Neuronalen Netze und der unterschiedlichen Abtastfrequenzen im Vergleich zur gemessenen Leistung aus dem regulären Fahrgastbetrieb auf.

Prädizierte und gemessene Leistung haben durch Fitness-Werte von mindestens 93% eine hohe Übereinstimmung. Durch die verringerte Abtastrate kommt eine Filterung zur Geltung, welche ein Overfitting vermeidet. Ein solches Overfitting ist für 10 Hz in Abbildung 5.8 im Beschleunigungsvorgang zwischen 5 und 15 Sekunden zu sehen.

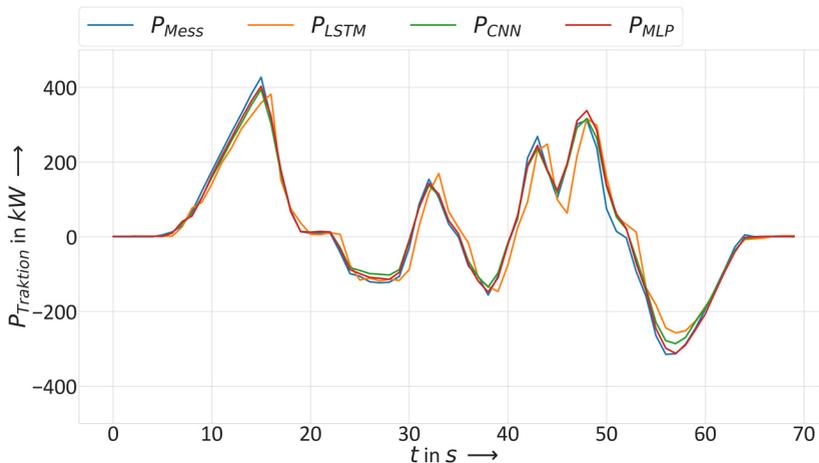


Abbildung 5.5: Prädiktion der Traktionsleistung der Neuronalen Netze für eine Abtastfrequenz von 1 Hz nach Tesar [207]

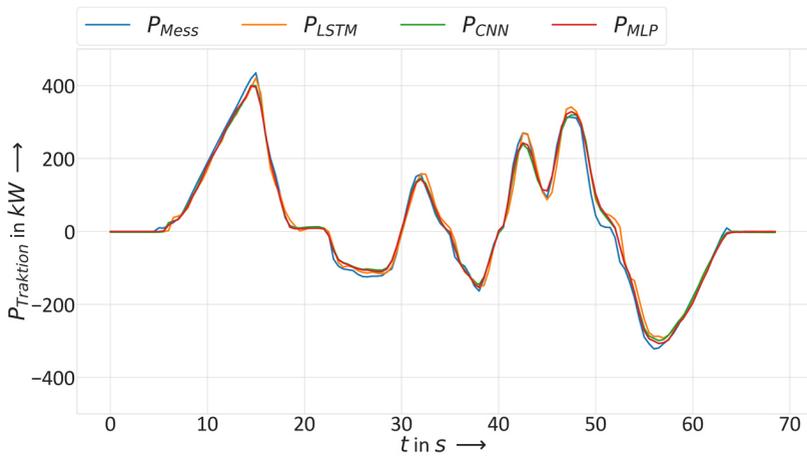


Abbildung 5.6: Prädiktion der Traktionsleistung der Neuronalen Netze für eine Abtastfrequenz von 2 Hz nach Tesar [207]

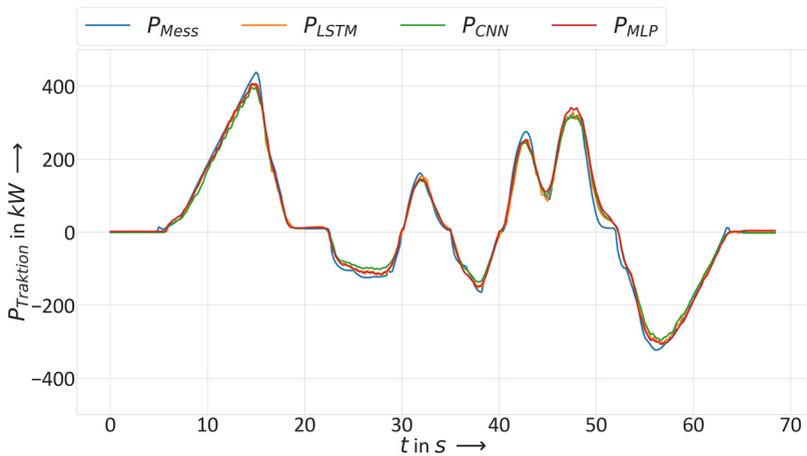


Abbildung 5.7: Prädiktion der Traktionsleistung der Neuronalen Netze für eine Abtastfrequenz von 5 Hz nach Tesar [207]

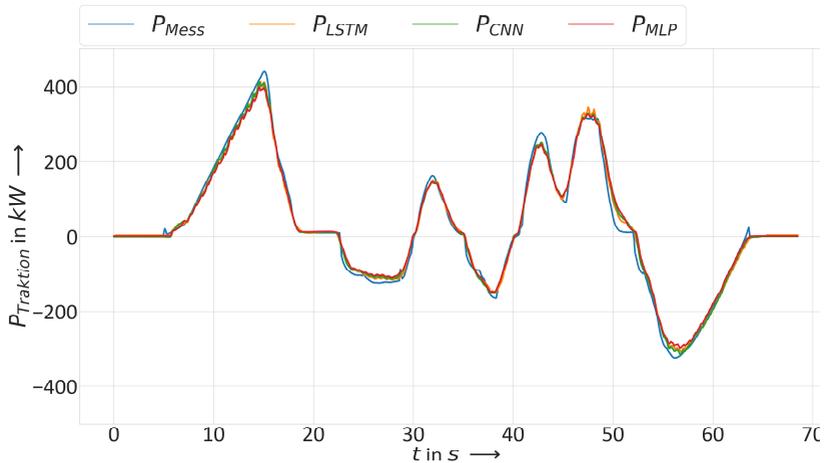


Abbildung 5.8: Prädiktion der Traktionsleistung der Neuronalen Netze für eine Abtastfrequenz von 10 Hz nach Tesar [207]

Mesoskopische Modellierung

In Tabelle 5.10 sind die Ergebnisse der mesoskopischen Modellierung des Traktionsenergiebedarfs aufgelistet. Es werden die besten Modelle hinsichtlich des MAPE und deren Netzwerkarchitekturen sowie die Klassenanzahl der Histogramme aufgeführt. Verglichen werden ebenfalls die Durchschnittswerte des Korrelationskoeffizienten r , des MAPE sowie der Rechenzeit auf den 617 Haltestellenintervallen, die weder im Trainings- noch im Testdatensatz enthalten sind. Eine Fitness-Funktion wird nicht aufgestellt, da keine Berechnung der Traktionsleistung in jedem Zeitschritt erfolgt.

Für den mesoskopischen Ansatz lässt sich feststellen, dass die Abtastfrequenz keinen signifikanten Einfluss auf die Prädiktion des Energiebedarfs hat. MLP schneiden auf dem Validierungsdatensatz besser als CNN ab. CNN weisen durchweg Abweichungen von mehr als 10 % zwischen dem prädizierten und

dem gemessenen Energiebedarf aus dem Fahrgastbetrieb auf. Die Korrelationskoeffizienten von MLP und CNN sind für alle Modelle größer 0,93. Die Klassenanzahl der Histogramme unterscheidet sich zwischen den besten MLP und CNN. Für CNN haben die besten Modelle eine feinere Auflösung der Histogramme als bei MLP. Die geringste und die feinste Auflösung haben sowohl bei CNN als auch bei MLP zu einer Verschlechterung der Ergebnisse geführt. [207]

Die Berechnungszeiten unterscheiden sich nicht für die einzelnen Abtastfrequenzen, da jeweils nur eine Prädiktion für ein Haltestellenintervall durchgeführt wird. Die Rechenzeiten von MLP und CNN unterscheiden sich ebenfalls nicht. Die Dauer zur Vorverarbeitung der Daten zu einem Histogramm hat nahezu keinen Einfluss auf die Berechnungsdauer. Obwohl zusätzliche Dimensionen im Gegensatz zu Topić [215] hinzugefügt werden, unterscheiden sich die Rechenzeiten nicht voneinander. [207]

Tabelle 5.10: Architektur und Ergebnisse der mesoskopischen Modellierung des Energiebedarfs nach Tesar [207]

Mesoskopisch	Architektur						Ergebnisse		
	Klassen	Schicht m	Neuronen Schicht m	Schicht n	Neuronen Schicht n	Dropout	r	MAPE	Rechen- zeit /s
MLP 1Hz	(10,10,11,4)	1 VVN	96	2 VVN	24	0 %	0,960	9,47 %	0,02
MLP 2 Hz	(10,10,11,4)	1 VVN	96	2 VVN	24	0 %	0,969	8,98 %	0,02
MLP 5 Hz	(10,10,11,4)	1 VVN	96	1 VVN	24	0 %	0,963	9,34 %	0,02
MLP 10 Hz	(10,10,11,4)	1 VVN	48	2 VVN	24	0 %	0,957	10,06 %	0,02
CNN 1 Hz	(20,20,22,4)	1 FS	-	1 VVN	96	5 %	0,951	11,17 %	0,02
CNN 2 Hz	(20,20,22,4)	1 FS	-	1 VVN	48	10 %	0,950	11,74 %	0,02
CNN 5 Hz	(20,20,22,4)	1 FS	-	1 VVN	48	5 %	0,940	11,48 %	0,02
CNN 10 Hz	(20,20,22,4)	1 FS	-	1 VVN	48	0 %	0,936	11,94 %	0,02

Vergleich der mikroskopischen und mesoskopischen Modellierung

Sowohl mit dem mikroskopischen als auch mit dem mesoskopischen Ansatz kann der Energiebedarf mit nur geringem Fehler (vgl. Tabelle 5.9 und 5.10) zuverlässig und mit geringer Rechenzeit vorhergesagt werden. Abbildung 5.9 zeigt den durchschnittlichen absoluten Fehler der Black-Box-Modelle auf dem Evaluationsdatensatz mit 617 Haltestellenintervallen. Für die einzelnen Abtastfrequenzen umfassen die Modelle sämtliche trainierte Neuronale Netze der Grid Search. Es ist zu erkennen, dass mit steigender Abtastfrequenz der durchschnittliche MAPE für die mikroskopischen Modelle abnimmt. Durch die höhere Abtastfrequenz können höherdynamischere Vorgänge abgebildet werden. Zwischen einer Abtastung mit 1 Hz und einer Abtastung mit 10 Hz liegt für mikroskopische Modelle im Mittel ein Unterschied des MAPE von 4 %.

Für den mesoskopischen Modellierungsinput führt eine erhöhte Abtastrate zu einer Verschlechterung der Energiebedarfsprädiktion. Durch die Reduzierung des Informationsgehalts mit geringen Abtastfrequenzen vereinfacht sich der Lernprozess für die Neuronale Netze. Dadurch ist die Prädiktion der 1 Hz Modell im Durchschnitt um knapp 3 % besser als die der 10 Hz Modelle.

Bei alleiniger Betrachtung der Abweichung der Energiebedarfsprädiktion ist der mikroskopische Ansatz dem mesoskopischen deutlich überlegen. Im Mittel über alle Abtastfrequenzen wird der Energiebedarf von mikroskopischen Modellen mit 11 % weniger Abweichung präzisiert.

In Anhang A.2 wird ein Überblick über die Auswirkungen der einzelnen Designparameter der Grid Search der mikroskopischen und mesoskopischen Modellierung gegeben.

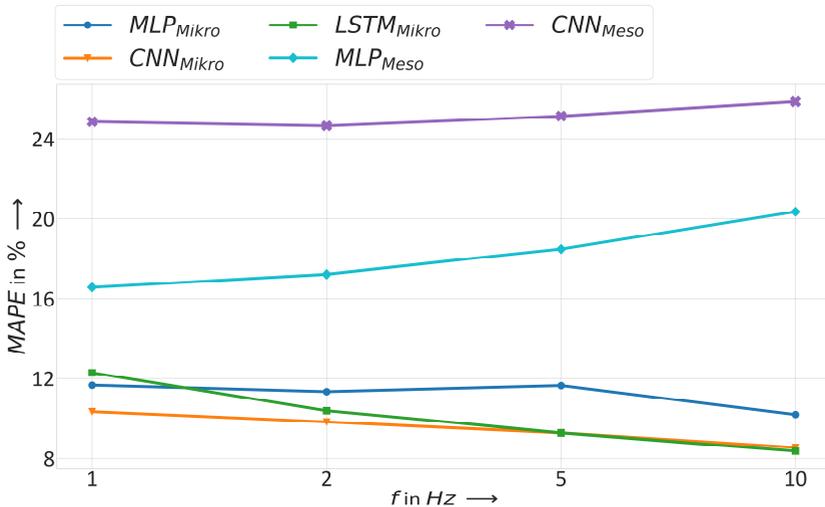


Abbildung 5.9: Durchschnittlicher absoluter Fehler der Black-Box-Modelle in Abhängigkeit der Abtastfrequenz im Vergleich zum Evaluationsdatensatz der Messstraßenbahn

Die Abbildungen 5.10 (a) und (b) zeigen die Prädiktion des Energiebedarfs der besten MLP-Modelle hinsichtlich des MAPE für eine Abtastfrequenz von 1 Hz für mikroskopischen und mesoskopischen Modellierungsinput. Die Prädiktion wird auf den 617 Haltestellenintervallen des Evaluationsdatensatzes durchgeführt. Aufgetragen ist die prädiizierte Energie $E_{Prädiktion}$ der Neuronalen Netze über der gemessenen Energie $E_{Messung}$ des jeweiligen Haltestellenabschnitts. Die grüne Gerade stellt den idealen Fall eines Korrelationskoeffizienten von $r = 1$ dar. Dabei würde jeder simulierte Wert dem Messwert entsprechen. Die blaue Gerade ist die Ausgleichsgerade durch den prädiizierten Energiebedarf der jeweiligen Modelle. In beiden Fällen resultiert eine hohe Übereinstimmung der Ausgleichsgeraden aufgrund des Korrelationskoeffizienten von größer 0,96. Dennoch ist die Streuung der mesoskopischen Modellierung durch den höheren MAPE stärker ausgeprägt. Das mikroskopische Modell weist einen MAPE von 6,74 % auf, das mesoskopische von 9,47 %. Damit liegen beide Modelle wesentlich unterhalb der durchschnittlichen Werte

nach Abbildung 5.9. Ebenfalls ist die Abweichung zwischen mikroskopischem und mesoskopischem Modell geringer. Die Architekturen der beiden Modelle sind Tabelle 5.9 und 5.10 zu entnehmen.

Weitere Prädiktionen auf dem Evaluationsdatensatz der trainierten Modelle nach Tabellen 5.9 und 5.10 sind in Anhang A.3 dargestellt.

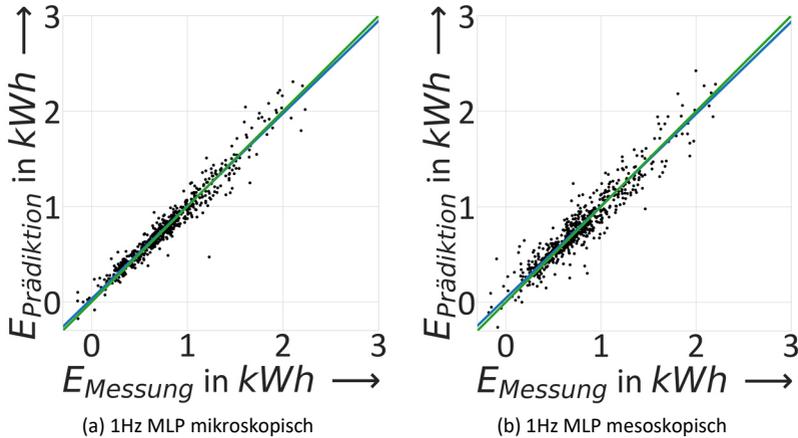


Abbildung 5.10: Vergleich der Prädiktion mit mikroskopischem und mesoskopischen Modellierungsinput auf dem Evaluationsdatensatz der Messstraßenbahn nach Tesar [207]

Die durchschnittliche Berechnungsdauer $t_{\text{Berechnung}}$ der jeweiligen Neuronalen Netze und des Modellierungsinputs in Zusammenhang mit der Abtastfrequenz ist in Abbildung 5.11 dargestellt. Mesoskopische MLP und CNN berechnen den Energiebedarf eines Haltestellenabschnitts in durchschnittlich 0,02 Sekunden unabhängig von der Abtastfrequenz. Bei den mikroskopischen Modellen stellt sich ein linearer Zusammenhang ein. Die Berechnungsdauer eines 1 Hz MLP beläuft sich auf durchschnittlich 0,07 Sekunden, die eines 10 Hz MLP auf 0,72 Sekunden. Diese Zusammenhänge sind ebenfalls für mikroskopische CNN und LSTM zu beobachten. 1 Hz CNN benötigen für die Energiebedarf-

sprädiktion im Durchschnitt 0,14 Sekunden, die 10 Hz Variante 1,38 Sekunden. Die längste Rechenzeit der Neuronalen Netze weisen LSTM auf. 1 Hz Modelle benötigen durchschnittlich 0,45 Sekunden. 10 Hz Modelle haben eine durchschnittliche Berechnungsdauer von 4,5 Sekunden für ein Haltestellenintervall. Die Berechnungsdauer der 10 Hz LSTM-Modelle ist dabei noch immer um das Dreifache schneller als das MPS.

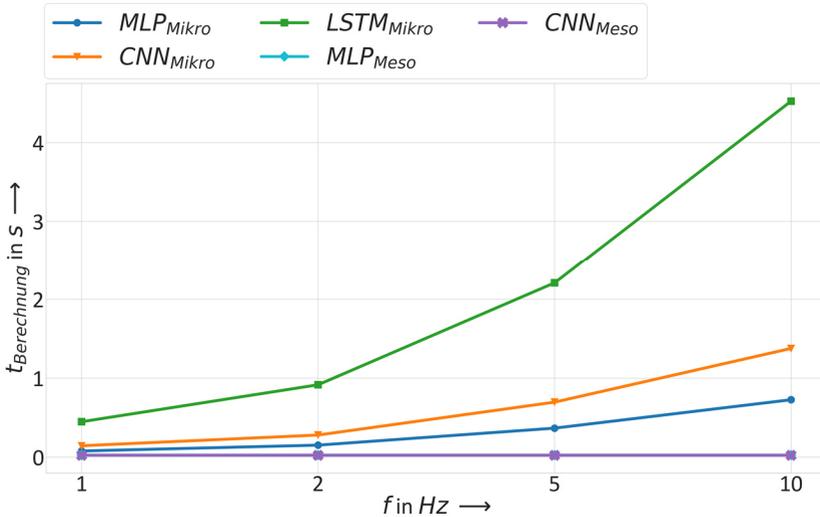


Abbildung 5.11: Durchschnittliche Berechnungsdauer der Black-Box-Modelle

Bei alleiniger Betrachtung der Berechnungsdauer ist der mesoskopische Ansatz dem mikroskopischen deutlich überlegen. Selbst im 1 Hz Fall ist die Vorhersage des Energiebedarfs noch um mehr als das Dreifache schneller. Falls eine erhöhte Abtastfrequenz seitens der Simulationsumgebung gefordert ist, verstärkt sich dieser Effekt noch weiter um mehr als den Faktor 30.

5.1.4 Diskussion

Tabelle 5.9 zeigt, dass eine mikroskopische Modellierung mit 1 Hz eine vergleichbare Genauigkeit zu den 10 Hz Varianten aufweist. Das beste 1 Hz Modell ist das trainierte MLP mit einem MAPE von 6,74 %, während das 10 Hz LSTM mit einem MAPE von 5,79 % den geringsten Fehler aller trainierten Modelle zeigt. Das 1 Hz MLP benötigt für die Berechnung des Energiebedarfs in einem Haltestellenabschnitt durchschnittlich 0,06 Sekunden. Mit dem 10 Hz LSTM werden pro Haltestellenabschnitt für die Energiebedarfsberechnung 3,63 Sekunden benötigt. In der weiteren Anwendung zum Training der Deep-RL-Agenten würde alleine die Rechenzeit des 10 Hz LSTM für ein Szenario mit vier Haltestellenabschnitten und 3500 Trainingsepisoden (vgl. Tabelle 5.11) mehr als 14 Stunden Zeit in Anspruch nehmen. Im Vergleich dazu liegt das 1 Hz MLP bei weniger als 15 Minuten. Zudem kann bei Verwendung des 1 Hz MLP das spätere Deep-RL-System sämtliche Berechnungen mit 1 Hz durchführen, was die gesamte Berechnungsdauer zusätzlich reduziert. Daher wird im weiteren Verlauf zur Berechnung des Energiebedarfs das mikroskopische 1 Hz MLP verwendet. Zudem hat sich gezeigt, dass MLP als Netzwerkarchitektur geeignet sind, das zugrundeliegende physikalische Problem mit vollvernetzten Schichten zu approximieren.

Bei der Entscheidung zur Verwendung von mikroskopischen und mesoskopischen Modellen ist ebenfalls der Zielkonflikt zwischen Genauigkeit und Rechenzeit für die Applikation abzuwägen. Mikroskopische Modelle sind genauer, benötigen jedoch länger in der Berechnung. Für die Anwendung im Deep-RL zum Training energieeffizienter und pünktlicher Fahrtrajektorien ist jedoch anzunehmen, dass mikroskopische Modelle zu einer schnelleren Konvergenz führen. Diese Annahme ist begründet durch das direkte Feedback, welches der Deep-RL-Agent in jedem Zeitschritt zum aktuellen Leistungsbedarf erhält. Bei einem mesoskopischen Modell würde der Agent die Rückmeldung zum Gesamtenergiebedarf erst an der nächsten Haltestelle erhalten. Dadurch ist es schwieriger für den Agenten, einzelne nicht energieeffiziente

Zustände in der gesamten Fahrtrajektorie zu identifizieren und daraus zu lernen. Mesoskopische Modelle könnten beispielsweise in der Analyse des Flottenenergiebedarfs eingesetzt werden.

Im Vergleich zu bisherigen Black-Box-Ansätzen aus der Literatur zur Modellierung des Energiebedarfs eines Elektrofahrzeugs durch Rhode [173] und von Schienenfahrzeugen im Metro-Einsatz durch Pineda-Jaramillo [161] zeigt die Modellierung höhere Genauigkeiten auf. Diese erhöhte Genauigkeit ist zum einen auf die Datengrundlage mit mehreren Millionen Datenpunkten sowie zum anderen auf die ausgedehnte Grid Search zurückzuführen. Dadurch kann eine Netzwerkarchitektur mit einer Genauigkeit von mehr als 93 % bei gleichzeitig geringer Berechnungsdauer von 0,06 Sekunden für die mikroskopische Modellierung ermittelt werden.

Sämtliche mikroskopische Black-Box-Modelle weisen eine höhere Genauigkeit und eine schnellere Rechenzeit als das am Institut erstellte Multi-Physik-Simulationsmodell auf. Durch das Lernen direkt aus den Daten werden durch das Modell inhärente systemische Zusammenhänge erlernt, welche in einem physikalischen Modellierungsansatz nicht gesamtheitlich berücksichtigt werden können. Ein Nachteil der Black-Box-Modellierung ist jedoch, dass Anpassungen am Modell durch den reinen datengetriebenen Bezug nicht möglich sind.

Weitere Verbesserungen an der Genauigkeit können durch genaue Messungen der Fahrgastzahlen, der Berücksichtigung von Windverhältnissen, des Schienenzustands sowie des Schientyps erfolgen.

5.2 Infrastruktur- und Betriebsmodell

5.2.1 Infrastrukturmodell

Auf Grundlage von digitalen Geländemodellen, Lageplänen und dem Geschwindigkeitsheft der AVG wird ein Infrastrukturmodell des Karlsruher Streckennetzes abgeleitet. Mit diesem stehen für jeden Meter der Strecke der Kurvenradius, die Steigung und die Streckenhöchstgeschwindigkeit zur Verfügung. Für die Implementierung im Deep-RL-System werden Anpassungen vorgenommen. Diese Anpassungen sind beispielhaft für den Streckenabschnitt von der Poststraße zum Hauptbahnhof in der Abbildung 5.12 dargestellt. Ungefähr bei Streckenmeter 400 befindet sich auf dem Streckenabschnitt eine S-Kurve mit Bogenradien kleiner 30 Meter. Hierfür werden im Geschwindigkeitsheft keine expliziten Höchstgeschwindigkeiten angegeben. Nach den Technischen Regeln für Straßenbahnen (TRStrab) ist eine maximale Querbeschleunigung von $0,98 \text{ m/s}^2$ im Fahrgastraum zulässig [203]. Im regulären Fahrgastbetrieb konnten zum Teil Überschreitungen von bis zu 80 % der maximal zulässigen Querbeschleunigungen beobachtet werden [181], wodurch der Fahrgastkomfort [46] beeinträchtigt wird. Diese Überschreitungen treten vermehrt im hinteren Wagenteil auf, wenn der Fahrer bereits aus der Kurve herausbeschleunigt, sich der hintere Teil des Fahrzeugs jedoch noch in der Kurve befindet [181]. Zudem wirken sich nach Heck [89] hohe Querbeschleunigungen in engen Kurven nicht nur auf den Komfort, sondern auch auf den Verschleiß aus. Daher werden die maximal zulässigen Kurvengeschwindigkeiten für den Agenten in der Umgebung angepasst. Für den Streckenabschnitt in Abbildung 5.12 ist die Höchstgeschwindigkeit v_{max} ohne Berücksichtigung des Kurvenradius in blau und mit der Berücksichtigung der maximalen Querbeschleunigung in orange dargestellt. Abgesehen von der Fahrt durch die S-Kurve unterscheiden sich die Streckenhöchstgeschwindigkeiten nicht. Die maximale Geschwindigkeit innerhalb der Kurve wird durch den geringsten Radius des Gleisbogens definiert. Auf den Streckenmeter, an welchem die zuläs-

sige Streckenhöchstgeschwindigkeit wieder möglich ist, wird noch die Fahrzeuglänge von 37,2 m addiert. Dadurch wird sichergestellt, dass sich kein Teil des Fahrzeugs mehr in der Kurve befindet. Mit der Beschränkung der Kurvenhöchstgeschwindigkeit kann durch die Fahrprofile der KI zusätzlich der Fahrgastkomfort erhöht und der Verschleiß reduziert werden.

Des Weiteren wird für den Agenten ein unteres Band für die Geschwindigkeit v_{UB} definiert. Dieses ist auf allen Streckenabschnitten identisch. Zu Beginn steigt v_{UB} mit 30 % der maximal möglichen Beschleunigung auf 5 km/h an. Diese Geschwindigkeit bleibt bis kurz vor der nächsten Haltestelle unverändert und erreicht erst vier Meter vor dem Halt wieder 0 km/h. Dieses untere Band fließt in die spätere Rewardfunktion ein und unterstützt den Trainingsprozess der KI beim Anfahren und Verzögern.

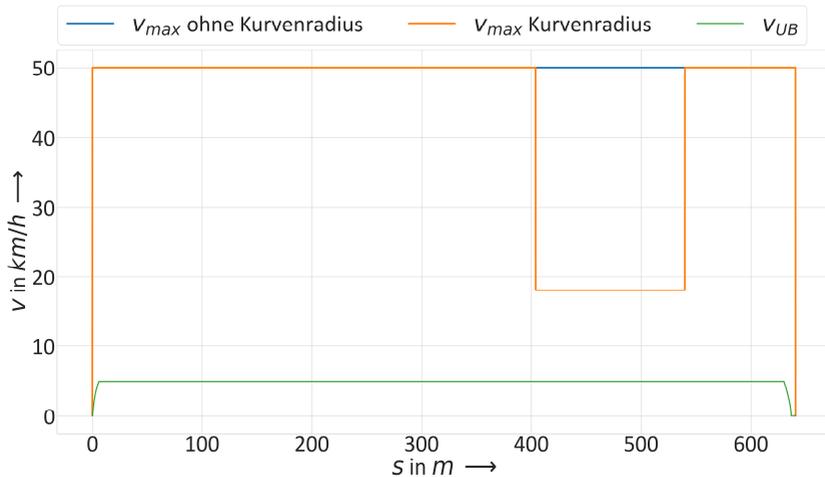


Abbildung 5.12: Angepasstes Infrastrukturmodell mit kurvenradiusabhängiger Maximalgeschwindigkeit sowie einem unteren Geschwindigkeitsband nach Tesar [213]

5.2.2 Betriebsmodell

Das Betriebsmodell (vgl. Kapitel 4.2.2) wird ebenfalls auf der Datengrundlage der Karlsruher Messstraßenbahn und den Fahrgaststatistiken der AVG aufgebaut. Es umfasst die durchschnittlichen Fahrzeiten und Haltedauern auf den einzelnen Linien des Karlsruher Straßenbahnnetzes zu den verschiedenen Betriebsstunden [94, 186].

5.3 Aktionsraum Agent

In der Modellierung des Aktionsraums wird festgelegt, mit welchen Aktionen der Deep-RL-Agent mit seiner Umgebung interagieren kann. Im vorliegenden Anwendungsfall kann der Deep-RL-Agent durch die Wahl der Längsbeschleunigung mit der Umgebung interagieren. Die maximale Beschleunigung und Verzögerung sind in Abbildung 5.13 dargestellt. Diese Grenzen basieren auf Aufzeichnungen der Fahrdynamik der Karlsruher Messstraßenbahn. Die Werte der Grenzkennlinien sind auf solche Werte beschränkt, die im Rahmen der Zugkraftbegrenzung tatsächlich erreicht werden können. Zugrunde liegen dabei eine ebene Strecke sowie eine Fahrgastauslastung von mindestens einem Drittel nach der Passagierstatistik. [213]

Die Verwendung der Grenzkennlinien stellt sicher, dass der Trainingsbereich des Fahrzeugmodells aus Kapitel 5.1 nicht verlassen wird, da Neuronale Netze grundsätzlich Schwierigkeiten in der Extrapolation haben. Zudem kann durch die Begrenzung garantiert werden, dass die KI fahrdynamisch realistische Geschwindigkeitsprofile generiert. [213]

Innerhalb der Grenzkennlinien kann die KI kontinuierlich jede Längsbeschleunigung wählen und ist nicht durch eine Diskretisierung des Aktionsraums limitiert. Dies entspricht der Fahrzeugführung aus dem realen Betrieb der Messstraßenbahn, was eine Vergleichbarkeit zwischen der KI und Fahrern aus dem täglichen Betrieb ermöglicht. [213]

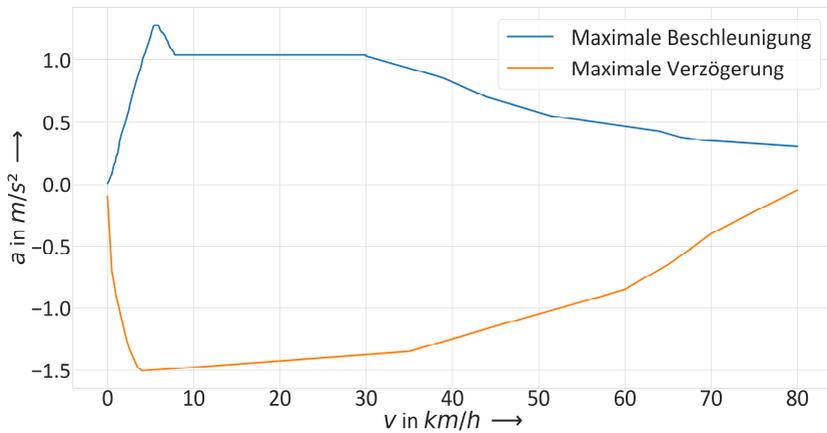


Abbildung 5.13: Grenzkennlinien für Beschleunigung und Verzögerung nach Tesar [213]

5.4 Beobachtungsraum

Deep-RL-Umgebungen werden in vollständig und teilweise beobachtbare Umgebungen unterschieden. Bei vollständig beobachtbaren Umgebungen ist jeder in der Umgebung berechnete Zustand für den Agenten einsehbar. Grundsätzlich kann durch eine nur teilweise beobachtbare Umgebung die Konvergenz des Lernprozesses beschleunigt werden. Dadurch, dass lediglich die für die Zielgrößen relevanten Zustände an den Agenten zurückgegeben werden, kann dieser schneller Korrelationen zwischen den eigenen Aktionen und deren Auswirkungen erlernen.

In dieser Dissertation wird daher nach Tesar [212] eine teilweise beobachtbare Umgebung gewählt. Die beobachtbaren Größen des Agenten umfassen die momentan maximal zulässige Geschwindigkeit sowie die Distanz bis zum nächsten Geschwindigkeitslimit und dessen Höhe. Zudem erhält der Agent eine Rückmeldung zur verbleibenden Distanz sowie zur verbleibenden Zeit nach Fahrplan bis zur nächsten Haltestelle. Weitere Rückmeldungen von der

Umgebung erhält der Agent anhand des Traktionsenergiebedarfs, der Traktionsleistung in jedem Zeitschritt sowie der letzten vorgenommenen Aktion. Zusätzliche beobachtbare Zustände sind die Steigung und der Kurvenradius der Strecke.

5.5 Rewardfunktion

Die Rewardfunktion wird in sofortige und anlassbezogene Rewards sowie Abbruchkriterien unterteilt. Sofortige Rewards werden in jedem Zeitschritt vergeben. Anlassbezogene Rewards erhält der Agent, wenn eine Haltestelle erreicht wird. Abbruchkriterien kommen bei schwerwiegendem Fehlverhalten des Agenten zu tragen, wodurch die Trainingsepisode beendet wird.

Die einzelnen Rewards nach Tesar [212] basieren auf dem Systemwissen der Anwender sowie einem sequentiellen Tuning in einer Vielzahl an Vorstudien. Nach Laud [126] sollten sofortige Belohnungsfunktionen möglichst kleine und stetige Übergänge haben.

Die Rewardfunktion ist dimensionslos. In der Umgebung sind sämtliche Größen normiert, damit die Neuronalen Netze des Deep-RL-Agenten besser lernen können und nicht durch Fehlergradienten einzelner Rewards überproportional beeinträchtigt werden. Die Beschleunigung wird auf den Wertebereich $[-1, 1]$ normiert, sämtliche weitere Größen in der Umgebung auf den Wertebereich $[0, 1]$. Die Normierung der Beschleunigung auf den oben genannten Wertebereich führt zu besseren Ergebnissen als eine Normierung auf den Bereich $[0, 1]$, da der Agent dadurch schneller erlernt, dass ein positiver Wert zu einer Beschleunigung und ein negativer Wert zur Verzögerung des Fahrzeugs führt. Die Maximal- und Minimalwerte der Beschleunigung entsprechen der maximal und minimal aufgezeichneten Beschleunigung im Datensatz nach Abbildung 5.13. Bei der Fahrzeit entspricht der Maximalwert 1 einer Zeit von 480 Sekunden. Dieser Wert ist die doppelte Zeit der längsten vorgesehenen Fahrzeit im Karlsruher Straßenbahnnetz von 240 Sekunden zwischen zwei

Haltestellen. Beim Energiebedarf beträgt das Maximum dem maximal gemessenen Energiebedarf im Datensatz der Karlsruher Messstraßenbahn, welcher zum Training des Energiebedarfsmodells genutzt wird.

Sofortige Rewards

Es werden zwei sofortige Rewards definiert. Der erste Reward r_1 nach Gleichung 5-2 belohnt das Fahren innerhalb des Geschwindigkeitslimits. Eine Überschreitung der zulässigen Höchstgeschwindigkeit v_{max} führt zu hohen negativen Rewards. Bei Unterschreitung der Geschwindigkeit des in Kapitel 5.2 definierten unteren Geschwindigkeitsbandes v_{UB} wird lediglich ein geringer negativer Reward vergeben. Der zweite sofortige Reward r_2 nach Formel 5-3 belohnt geringe Abweichungen in der Beschleunigung zwischen zwei Zeitschritten. Dies unterstützt den Agenten im Erlernen von Cruising- und Coasting-Strategien, da aufgrund des kontinuierlichen Aktionsraums eine Vielzahl von Aktionen möglich sind.

$$r_1 = \begin{cases} +80 & , v_t > v_{UB} \wedge v_t < v_{max} \\ -20 \cdot (v_{UB} - v_t) & , v_t < v_{UB} \\ -12000 \cdot (v_t - v_{max}) & , v_t > v_{max} \end{cases} \quad (5-2)$$

$$r_2 = -300 \cdot (a_t - a_{t-1})^2 \quad (5-3)$$

Anlassbezogene Rewards

Anlassbezogene Rewards erhält der Agent beim Erreichen der Haltestelle. Diese geben dem Agenten eine Rückmeldung, wie energieeffizient und pünktlich die gewählte Geschwindigkeitstrajektorie ist. Zudem lernt der Agent, ob korrekt an der Haltestelle angehalten wird.

Reward r_3 gibt dem Agenten nach Gleichung 5-4 eine hohe Belohnung, wenn zum Zeitpunkt des Erreichens der Haltestelle nach der Distanz s_{Halt} die Ge-

geschwindigkeit v_t kleiner gleich 1 km/h ist. Insofern die Geschwindigkeit größer 1 km/h ist, greift der zweite Fall des Rewards. Tritt dieser zweite Fall ein, wird zudem über Reward r_4 nach Formel 5-5 die Abweichung der Geschwindigkeit über 1 km/h bestraft.

Mittels des Rewards r_5 in Gleichung 5-6 erhält der Agent eine Rückmeldung zur Pünktlichkeit. Falls der Agent zur geplanten Zeit nach Fahrplan $t_{Fahrplan}$ die Haltestelle erreicht, wird kein negativer Reward vergeben. Jede Sekunde über- oder unterhalb der geplanten Zeit wird bestraft. Die betragsmäßige Differenz aus Fahrzeit und im Fahrplan vorgesehener Zeit wird als Fahrplanabweichung bezeichnet und an jeder Haltestelle ausgewertet. Der Reward r_6 belohnt nach Gleichung 5-7 energieeffizientes Fahren durch einen negativen Reward auf die benötigte Energie innerhalb eines Haltestellenintervalls.

$$r_3 = \begin{cases} +18000 & , s = s_{Halt} \wedge v_t \leq 1 \text{ km/h} \\ +6000 & , s = s_{Halt} \wedge v_t > 1 \text{ km/h} \end{cases} \quad (5-4)$$

$$r_4 = -\sqrt{v_t \cdot 1000} , s = s_{Halt} \wedge v_t > 1 \text{ km/h} \quad (5-5)$$

$$r_5 = -600 \cdot |t_{Fahrzeit} - t_{Fahrplan}| , s = s_{Halt} \quad (5-6)$$

$$r_6 = -8000 \cdot E_{Abschnitt} , s = s_{Halt} \quad (5-7)$$

Im Anhang A.4 sind Ergebnisse einer veränderten Rewardfunktion aufgelistet, bei welcher die Rewards r_5 und r_6 zur Pünktlichkeit und zum Energiebedarf verändert werden. Dabei wird eine erhöhte Gewichtung auf die Energieeffizienz und eine weniger hohe Gewichtung auf die Pünktlichkeit gelegt.

Abbruchkriterien

Bei grobem Fehlverhalten des Agenten wird die Episode abgebrochen. Dafür sind hohe negative Rewards vorgesehen. Reward r_7 in Gleichung 5-8 wird vergeben, sobald der Agent nahezu die doppelte im Fahrplan vorgesehene Zeit für den Haltestellenabschnitt benötigt. Falls der Agent die allgemein zulässige Höchstgeschwindigkeit des Fahrzeugs mit 80 km/h überschreitet, wird die Episode durch Reward r_8 nach Formel 5-9 ebenfalls abgebrochen.

$$r_7 = -505000, t_{\text{Fahrzeit}} > 1,95 \cdot t_{\text{Fahrplan}} \quad (5-8)$$

$$r_8 = -505000, v_t > 80 \text{ km/h} \quad (5-9)$$

5.6 Wahl und Parametrierung des Algorithmus

In dieser Dissertation wird ein TD3-Algorithmus nach Kapitel 2.1.4 implementiert. Die Hyperparameter zum Training des Agenten sind in Tabelle 5.11 aufgelistet.

Für jedes Szenario wird der Agent 3500 Episoden lang trainiert. Zu Beginn wird eine standardnormalverteilte Noise \mathcal{N} mit einem Mittelwert μ von 0 und einer Varianz σ^2 von 0,4 auf jede Aktion modelliert. Dadurch wird sichergestellt, dass der Agent neue Zustände exploriert und nicht in lokalen Optima verweilt. Diese Varianz wird zu Beginn jeder Episode verringert, bis sie kurz vor Episode 1500 den Wert 0 erreicht. Die letzten 2000 Episoden werden ohne äußere Einflüsse auf die Aktionen trainiert, da in einer späteren Anwendung ebenfalls kein Rauschen auf die Fahrprofile modelliert werden soll.

Nach jedem Zeitschritt wird im Replay Buffer \mathfrak{B} das Tupel aus dem aktuellen Zustand s_t , der gewählten Aktion a_t , dem daraus resultierenden Reward r_t und dem nächsten Zustand s_{t+1} gespeichert. Daraus kann der Agent lernen, welche Aktionen zu welchen Rewards führen. Durch die Vergrößerung des Replay Buffers werden mehr Tupel gespeichert, wodurch die Dauer des Lernprozesses steigt, das Training jedoch an Stabilität gewinnt [67].

Actor- und Critic-Netzwerke sind nicht identisch und unterscheiden sich in der ersten Schicht. Die erste Schicht des Actor-Netzwerks umfasst sämtliche beobachtbaren Zustände, während die Critic-Netzwerke neben den Beobachtungen noch die Aktion des Actors verarbeiten. In Voruntersuchungen wurde der Parameterraum zwischen drei und sieben Schichten variiert mit Neuronenzahlen im Bereich zwischen 100 und 400. Bei der Architektur nach Tabelle 5.11 konnte in diesen ersten Untersuchungen weder Over- noch Underfitting festgestellt werden. Für die Parameteranpassungen der Neuronalen Netze wird eine Lernrate α von 0,0002 mit der Adam-Optimierung zur intelligenten Schrittweitenanpassung gewählt. Zum Training werden über die Batch Size jeweils 1000 Tupel aus dem Replay Buffer genutzt, um die Parameter der Neuronalen Netze anzupassen.

Der Discount Factor γ ist mit 0,995 sehr hoch gewählt, da der Agent anlassbezogene Rewards zur Pünktlichkeit und zur Energieeffizienz erst beim Erreichen der Haltestelle erhält. Diese Rewards sollen vom Agenten priorisiert werden. Zur Stabilisierung des Trainings wird das Actor-Netzwerk alle drei Epochen aktualisiert und der Soft Update Factor τ der Target-Netzwerke beträgt 0,005.

Tabelle 5.11: Hyperparameter für den TD3-Algorithmus nach Tesar [213]

Hyperparameter	Wert
Anzahl Episoden	3500
Noise \mathcal{N}	$(\mu = 0, \sigma^2 = 0,4)$
Verringerung der Noise \mathcal{N} pro Episode	0,00027
Größe des Replay Buffers \mathfrak{B}	1000000
Anzahl Schichten der Neuronalen Netze	5
Neuronen in jeder Schicht des Actors	11 / 300 / 200 / 200 / 1
Neuronen in jeder Schicht des Critics	12 / 300 / 200 / 200 / 1
Lernrate α	0,0002
Batch Size	1000
Discount Factor γ	0.995
Updatefrequenz des Actors	3
Soft Update Faktor τ	0.005

In der aufgebauten und validierten Umgebung wird im Folgenden mit der definierten Rewardfunktion und dem parametrisierten Algorithmus untersucht, welches Potential Deep Reinforcement Learning zur Steigerung von Energieeffizienz und Pünktlichkeit aufweist.

6 Ergebnisse und Diskussion

Im sechsten Kapitel werden die Deep-RL-Agenten in der aufgebauten Umgebung aus Kapitel 5 trainiert und getestet (vgl. Abbildung 6.1). Zunächst werden auf zwei verschiedenen Szenarien zu drei Verkehrszeiten die Deep-RL-Agenten trainiert. Durch die valide Umgebung können die Fahrprofile der KI mit denen der Fahrer aus dem regulären Fahrgastbetrieb verglichen werden. Des Weiteren werden die Fahrprofile mit einem durch Dynamic Programming ermittelten theoretischen Optimum verglichen. Erste Untersuchungen auf einem Szenario sind in [213, 214] veröffentlicht. Weitere Ergebnisse sind in [212] publiziert.

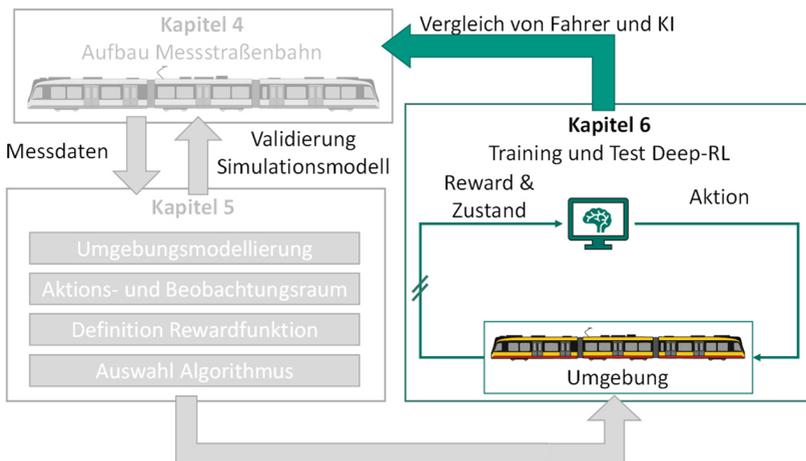


Abbildung 6.1: Einordnung des sechsten Kapitels in den Lösungsansatz

Um die Eignung eines Einsatzes in einem Assistenzsystem nachzuweisen, werden in einem nachgelagerten Schritt die Generalisierungsfähigkeiten der trainierten KI unter unbekanntem Haltedauern untersucht. Anschließend wird

eine Umleitungsfahrt auf einem unbekanntem Streckenabschnitt ohne weiteres Training der KI durchgeführt.

6.1 Trainings- und Testszenarien

Training und Test der Deep-RL-Agenten werden auf drei Streckenabschnitten durchgeführt, welche im Folgenden vorgestellt werden. Auf den Szenarien 1 und 2 wird ein umfassendes Training der Agenten durchgeführt. Das dritte Szenario stellt den Testfall der Umleitungsfahrt dar.

6.1.1 Szenario 1: Tivoli bis Kolpingplatz

Das erste Szenario umfasst vier Haltestellenabschnitte und verläuft von der Haltestelle Tivoli bis zur Haltestelle Kolpingplatz durch die Karlsruher Südstadt. Befahren wird dieser Streckenabschnitt von der Linie 4 im Aufzeichnungszeitraum von 2019 bis 2021. Als Datengrundlage stehen 210 Fahrten zur Verfügung.

Im Szenario 1 wird insgesamt eine Strecke von 1679,7 Metern zurückgelegt. Die im Fahrplan vorgesehene Zeit beträgt 480 Sekunden. Abbildung 6.2 zeigt den Linienverlauf durch die Karlsruher Südstadt sowie die einzelnen Haltestellen dieses Streckenabschnitts. Zwischen dem Tivoli und der Poststraße sowie zwischen der Ebertstraße und dem Kolpingplatz teilt sich die Straßenbahn die Trasse mit dem Individualverkehr. Die Geschwindigkeitsbeschränkungen des ersten Szenarios sind in Abbildung 6.3 dargestellt. An zwei Stellen greifen kurvenradiusabhängige Höchstgeschwindigkeiten. Zum einen handelt es sich um die S-Kurve zwischen Tivoli und Poststraße und zum anderen um eine enge Rechtskurve nach der Haltestelle Ebertstraße in Richtung Kolpingplatz bei der Abbiegung in die Karlstraße. Das untere Geschwindigkeitsband ist auf 5 km/h gesetzt.



Abbildung 6.2: Linienverlauf und Haltestellen des ersten Szenarios von der Haltestelle Tivoli bis zur Haltestelle Kolpingplatz (erstellt mit ©Mapbox und ©OpenStreetMap)

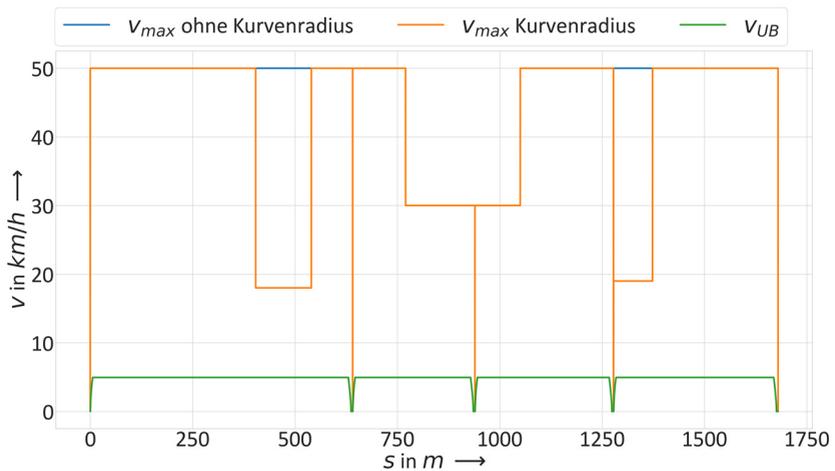


Abbildung 6.3: Geschwindigkeitsbeschränkungen des ersten Szenarios von der Haltestelle Tivoli bis zur Haltestelle Kolpingplatz nach Tesar [212]

Abbildung 6.4 zeigt die durchschnittlichen Haltezeiten an den jeweiligen Haltestellen. Zusätzlich gibt Tabelle 6.1 einen Überblick über die geplanten Fahrzeiten zwischen den Haltestellen und im Fahrplan vorgesehene Haltezeiten.

Lediglich am Hauptbahnhof ist eine geplante Verweildauer von 120 Sekunden vorgesehen. In allen weiteren Fällen hat die Haltedauer einen direkten Einfluss auf die verfügbare Fahrzeit im Haltestellenabschnitt. Aufgrund der vordefinierten Haltedauer am Hauptbahnhof ist diese nicht in Abbildung 6.4 aufgeführt.

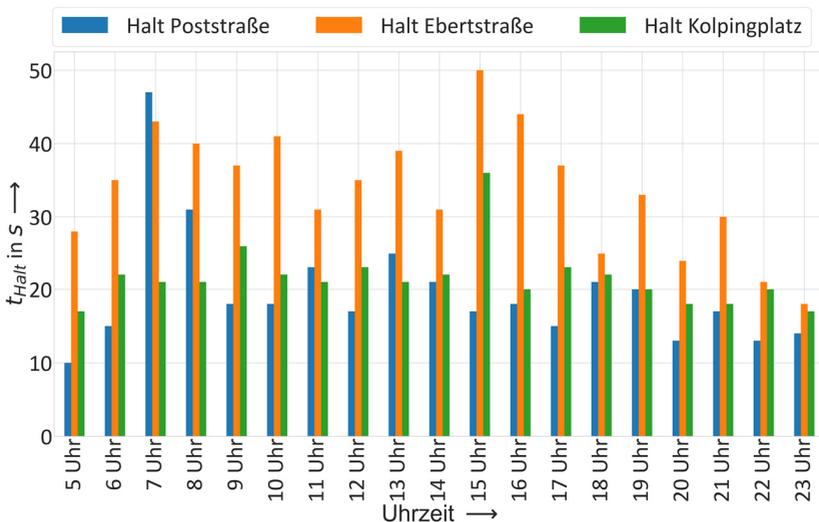


Abbildung 6.4: Durchschnittliche Haltedauern an den Haltestellen ohne im Fahrplan eingeplante Haltedauern im ersten Szenario nach Tesar [212]

Die Haltedauern an den einzelnen Haltestellen variieren in diesem Szenario stark. Im Mittel wird an den drei Haltestellen insgesamt 75 Sekunden lang gestoppt. Die Standardabweichung über den gesamten Tag beträgt 16 Sekunden. Der Streckenabschnitt verläuft über den Karlsruher Hauptbahnhof, weswegen es zu einem erhöhten Fahrgastaufkommen zu den Pendlerzeiten kommt.

Tabelle 6.1: Betriebsparameter für Szenario 1 nach Tesar [212]

Haltestellenintervall	Zeit nach Fahrplan	Eingeplante Haltedauer
Tivoli - Poststraße	120 s	-
Poststraße - Hauptbahnhof	60 s	120 s
Hauptbahnhof - Ebertstraße	60 s	-
Ebertstraße - Kolpingplatz	120 s	-

Zum Training der KI werden drei Verkehrszeiten identifiziert. Die Haltedauern um 5 Uhr repräsentieren die Schwachlastzeit, die Haltedauern um 7 Uhr die Hauptverkehrszeit und durch die Haltedauern um 11 Uhr wird die Nebenverkehrszeit dargestellt. Die Haltedauern um 5 Uhr umfassen sämtliche Fahrten von 5:00 Uhr bis 5:59 Uhr. Dies gilt ebenfalls für alle weiteren Uhrzeiten.

Das erste Szenario ist aufgrund der variablen Haltedauern speziell für die Untersuchung der Generalisierungsfähigkeiten von Bedeutung. Sowohl im Training als auch im späteren Test wird untersucht, wie die KI mit Situationen umgeht, in welchen aufgrund von hohen Verspätungen ein pünktliches Erreichen der Haltestelle nicht mehr möglich ist. Zudem kann ermittelt werden, welche Agenten unter welchen Trainingsbedingungen am besten generalisieren.

6.1.2 Szenario 2: Glogauer Straße bis Europäische Schule

Das zweite Szenario umfasst fünf Haltestellenabschnitte und verläuft von der Haltestelle Glogauer Straße bis zur Haltestelle Europäische Schule, welche die Endhaltestelle der Linie 4 im Aufzeichnungszeitraum von 2019 bis 2021 darstellt. Als Datengrundlage stehen 106 Fahrten zur Verfügung. Die reduzierte Anzahl an Fahrten im zweiten Szenario ist dadurch bedingt, dass die Hälfte der Fahrten bereits an der Haltestelle Jägerhaus endet.

Im zweiten Szenario beträgt die Streckenlänge 1986,6 Meter und im Fahrplan

vorgesehen ist eine Fahrzeit von 360 Sekunden. In Abbildung 6.5 sind der Linienverlauf durch die Karlsruher Waldstadt sowie die einzelnen Haltestellen dieses Streckenabschnitts dargestellt. Abbildung 6.6 zeigt die Geschwindigkeitsbeschränkungen des zweiten Szenarios. Die Streckenhöchstgeschwindigkeit liegt mit 60 km/h um 10 km/h höher als im ersten Szenario. An drei Stellen wird die Höchstgeschwindigkeit aufgrund des vorliegenden Kurvenradius reduziert. Die Geschwindigkeitsanpassungen sind auf Kurven nach der Haltestelle Jägerhaus, nach der Haltestelle Elbingerstraße und nach der Haltestelle Osteroderstraße zurückzuführen. Das untere Geschwindigkeitsband wird hier ebenfalls auf 5 km/h gesetzt.

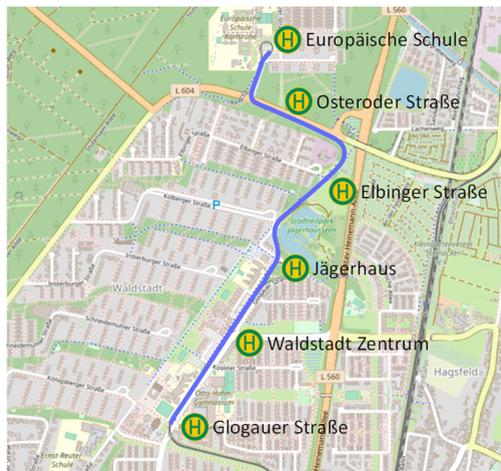


Abbildung 6.5: Linienverlauf und Haltestellen des zweiten Szenarios von der Haltestelle Glogauer Straße bis zur Haltestelle Europäische Schule (erstellt mit ©Mapbox und ©OpenStreetMap)

In Abbildung 6.7 sind die durchschnittlichen Haltedauern an den jeweiligen Haltestellen aufgezeigt. Die Endhaltestelle Europäische Schule ist nicht aufgeführt, da hier eine planmäßige Standzeit von mindestens 5 Minuten in der Wendeschleife vorgesehen ist. Tabelle 6.2 listet die im Fahrplan vorgesehenen Fahrzeiten zwischen den Haltestellen sowie die geplanten Haltedauern

auf. Abgesehen von der Endhaltestelle ist an keiner Haltestelle eine Halte-
dauer eingeplant, wodurch sich die Haltezeit wiederum direkt auf die verfü-
gbare Fahrzeit auswirkt.

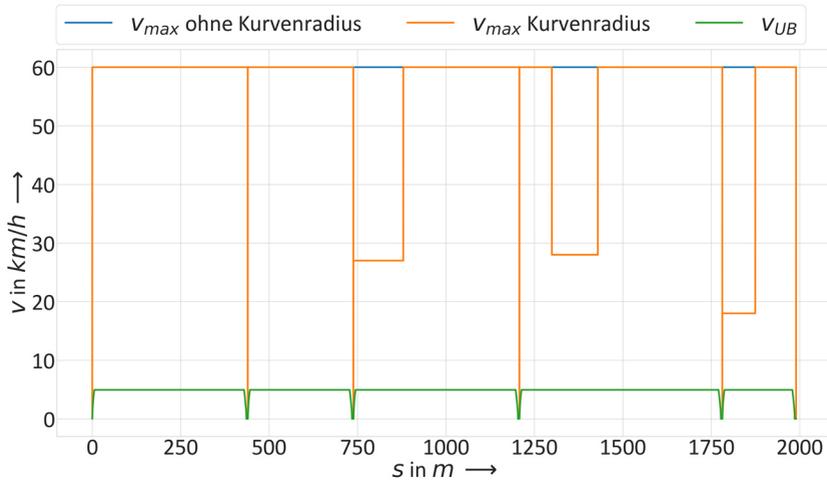


Abbildung 6.6: Geschwindigkeitsbeschränkungen des zweiten Szenarios von der Haltestelle Glogauer Straße bis zur Haltestelle Europäische Schule nach Tesar [212]

Die Haltezeiten an den einzelnen Haltestellen variieren in diesem Szenario weniger stark als in Szenario 1. Durchschnittlich wird an allen vier Haltestellen insgesamt 63 Sekunden gestoppt. Trotz einer zusätzlichen Haltestelle liegt dieser Wert 12 Sekunden unterhalb des Vergleichswerts aus Szenario 1. Die Standardabweichung der durchschnittlichen Haltezeit beträgt über den Tag lediglich 5 Sekunden und ist damit 11 Sekunden geringer als im ersten Szenario. Die Haltezeiten an einzelnen Haltestellen liegen beinahe ausschließlich zwischen 10 und 20 Sekunden. Forschungsarbeiten haben gezeigt, dass Haltezeiten in dieser Größenordnung einen unbeeinträchtigten Betrieb repräsentieren [18, 37].

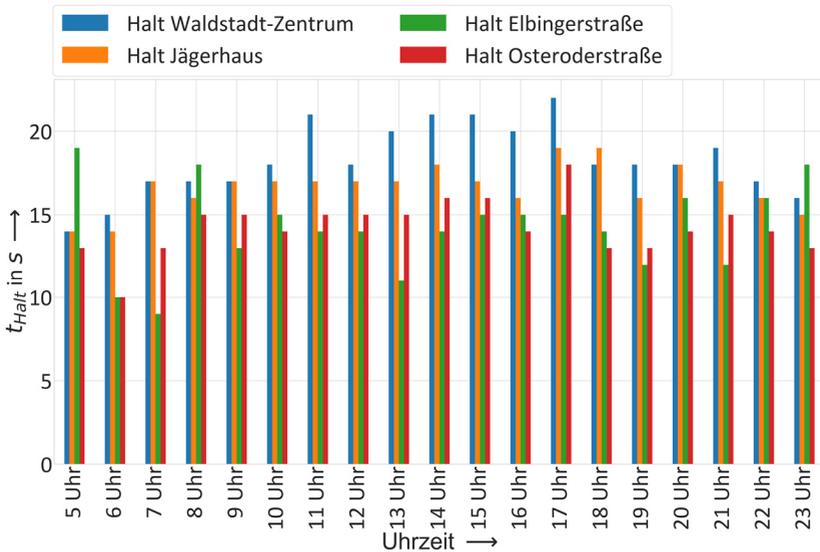


Abbildung 6.7: Durchschnittliche Haltedauern an den Haltestellen im zweiten Szenario nach Tesar [212]

Die KI wird erneut zu den drei Verkehrszeiten um 5 Uhr, 7 Uhr und 11 Uhr trainiert. Diese Verkehrszeiten unterscheiden sich im zweiten Szenario aufgrund des geringen Fahrgastaufkommens an den einzelnen Haltestellen kaum. Die eigentliche Hauptverkehrszeit um 7 Uhr weist mit einer Gesamthaltedauer von 56 Sekunden sogar die geringste Haltedauer der drei Verkehrszeiten auf. Aufgrund der geringen Varianz der Haltedauern ist das zweite Szenario für die Generalisierung weniger anspruchsvoll als das erste Szenario. Auf dem Streckenabschnitt des zweiten Szenarios gibt es durch die eigene Trasse keine Interaktion mit dem Individualverkehr. Damit ist durch dieses Szenario eine wechselwirkungsfreie Analyse zwischen den Fahrprofilen der Fahrer und der KI möglich.

Tabelle 6.2: Betriebsparameter für Szenario 2 nach Tesar [212]

Haltestellenintervall	Zeit nach Fahrplan	Eingeplante Haltedauer
Glogauer Straße - Waldstadt-Zentrum	60 s	-
Waldstadt-Zentrum - Jägerhaus	60 s	-
Jägerhaus – Elbinger Straße	60 s	-
Elbinger Straße - Osteroder Straße	120 s	-
Osteroder Straße -Europäische Schule	60 s	Standzeit \geq 5 Minuten

6.1.3 Szenario 3: Durlacher Tor bis Tivoli

Das dritte Szenario umfasst vier Haltestellenabschnitte und verläuft von der Haltestelle Durlacher Tor bis zur Haltestelle Tivoli. Dieser Abschnitt wird von der Linie 2 im Aufzeichnungszeitraum von 2019 bis 2021 befahren. Als Datengrundlage stehen 86 Fahrten zur Verfügung.

Im dritten Szenario beträgt die Streckenlänge 1915,3 Meter und im Fahrplan vorgesehen ist eine Fahrzeit von 420 Sekunden. Abbildung 6.8 zeigt den Linienverlauf von der Karlsruher Oststadt in die Südstadt sowie die einzelnen Haltestellen dieses Streckenabschnitts. Zwischen dem Ruppurer Tor und der Werderstraße sowie zwischen der Werderstraße und dem Tivoli teilt sich die Straßenbahn die Trasse mit dem Individualverkehr. In Abbildung 6.9 sind die Geschwindigkeitsbeschränkungen für das dritte Szenario dargestellt. Wie im ersten Szenario liegt die Höchstgeschwindigkeit bei 50 km/h. Zwischen dem Durlacher Tor und dem Kronenplatz wird eine Linkskurve mit geringem Radius befahren, wodurch im ersten Haltestellenabschnitt eine Anpassung der Streckenhöchstgeschwindigkeit vorgenommen wird. Das untere Geschwindigkeitsband wird auch im dritten Szenario auf 5 km/h festgesetzt.

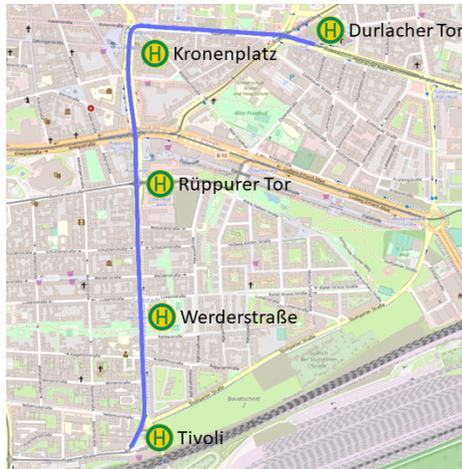


Abbildung 6.8: Linienverlauf und Haltestellen des dritten Szenarios von der Haltestelle Durlacher Tor bis zur Haltestelle Tivoli (erstellt mit ©Mapbox und ©OpenStreet-Map)

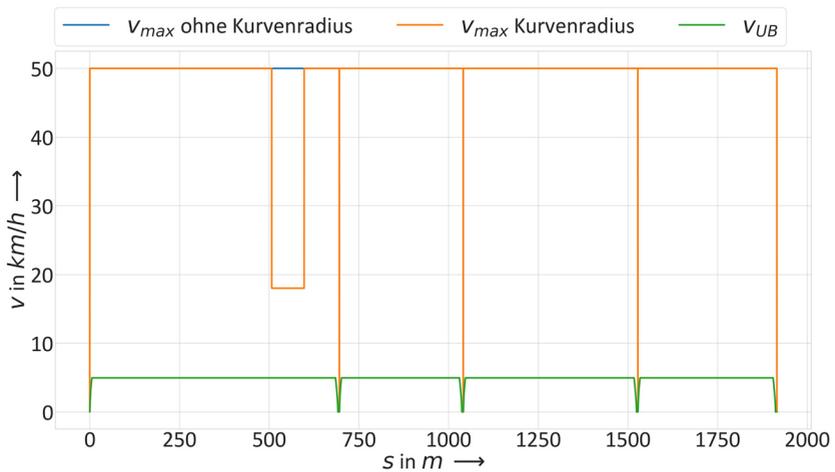


Abbildung 6.9: Geschwindigkeitsbeschränkungen des dritten Szenarios von der Haltestelle Durlacher Tor bis zur Haltestelle Tivoli nach Tesar [212]

Der Streckenabschnitt wird häufig als Umleitung genutzt, insofern Störungen auf der Kaiserstraße auftreten. Selbst im neuen Liniennetzplan dient der Streckenabschnitt als Umfahrung bei einer Störung im Stadtbahntunnel. Das dritte Szenario dient zur Untersuchung der Fähigkeiten zum Wissenstransfer der trainierten KI. Hierfür werden trainierte Agenten der ersten beiden Szenarien ohne weiteres Training eingesetzt und deren Fahrprofile hinsichtlich Energieeffizienz und Pünktlichkeit mit denen von Fahrern aus dem regulären Fahrgastbetrieb verglichen. Um einen fairen Vergleich durchzuführen, beschränkt sich das dritte Szenario auf Haltedauern zwischen 5 Uhr und 5:59 Uhr. Dadurch werden Wechselwirkungen mit dem Individualverkehr auf den letzten beiden Haltestellenabschnitten vermieden. Energieeffizienz und Pünktlichkeit der Fahrprofile der KI und der Fahrer sind damit besser vergleichbar.

Die betrieblich bedingten Haltedauern durch Fahrgastwechsel im ausgewählten Zeitraum sind in Tabelle 6.3 aufgelistet. An keiner Haltestelle ist eine Haltedauer im Fahrplan eingeplant. Die Haltedauern sind gleichmäßig verteilt und lassen keine Rückschlüsse auf eine Beeinträchtigung durch erhöhte Fahrgastströme zu.

Tabelle 6.3: Betriebsparameter für Szenario 3

Haltestellenintervall	Zeit nach Fahrplan	Nicht eingeplante Haltedauer im 5 Uhr Szenario
Durlacher Tor - Kronenplatz	120 s	23 s
Kronenplatz - Rüppurer Tor	120 s	20 s
Rüppurer Tor - Werderstraße	60 s	21 s
Werderstraße - Tivoli	120 s	27 s

6.2 Training Deep Reinforcement Learning Agent

Zunächst werden die Agenten auf den in 6.1.1 und 6.1.2 beschriebenen Szenarien zu den jeweiligen Haltedauern der Schwachlast-, Hauptverkehrs- und

Nebenverkehrszeit trainiert. Für jeden der insgesamt sechs Anwendungsfälle wird die Deep-RL-Umgebung aus Kapitel 5 mit den Infrastruktur- und Betriebsdaten parametrisiert. In jedem Szenario und zu jeder Auslastungszeit wird ein einzelner Agent für 3500 Episoden mit den Parametern nach Tabelle 5.11 trainiert. In der Folge werden daher insgesamt sechs Agenten parametrisiert. Als Vergleichsgrößen dienen der Energiebedarf auf dem Streckenabschnitt sowie die nach Gleichung 5-7 berechnete Fahrplanabweichung.

6.2.1 Training Szenario 1

Insgesamt wurden 27 Agenten für jede Verkehrszeit trainiert. Abbildung 6.10 zeigt die Fahrprofile der drei besten Agenten mit dem höchsten Reward für die jeweilige Verkehrszeit. Aufgetragen ist das Geschwindigkeitsprofil über die Distanz des gesamten Streckenabschnitts. Die rote Funktion zeigt die für jeden Streckenmeter gültige Höchstgeschwindigkeit. Die durch die KI ermittelten Fahrprofile sind in ihrer Grundgestalt ähnlich. Die zur Hauptverkehrszeit um 7 Uhr trainierte KI wählt die höchsten Geschwindigkeiten. Durch die Anpassung der Geschwindigkeitstrajektorie gelingt es dem 7 Uhr-Agenten, den längeren Haltedauern zur Hauptverkehrszeit entgegenzuwirken. Die weiteren Agenten reduzieren die Geschwindigkeit, um die Fahrwiderstände zu reduzieren und dadurch die Energieeffizienz zu erhöhen. Dies ist aufgrund der kürzeren Haltedauern nach Abbildung 6.4 möglich.

Die Auswirkungen der Fahrprofile auf die Fahrplanabweichung sowie den Energiebedarf sind in Tabelle 6.4 aufgelistet. Der Energiebedarf zur Hauptverkehrszeit um 7 Uhr liegt durch die höheren Geschwindigkeiten um 11,1 % über dem Energiebedarf der anderen beiden Verkehrszeiten. Aufgrund der längeren Standzeiten an den einzelnen Haltestellen um 7 Uhr (vgl. Abbildung 6.4) ist selbst mit einer angepassten Fahrtrajektorie nicht immer ein pünktliches Erreichen der Haltestellen möglich. Daher wird über alle vier Haltestellenabschnitte eine Fahrplanabweichung von 52 Sekunden akkumuliert. Im Gegensatz dazu sind die Fahrplanabweichungen für die Verkehrszeiten um 5 Uhr und 11 Uhr vergleichsweise gering. Die Fahrplanabweichung zur

Schwachlast- und Nebenverkehrszeit ist durch den dritten Haltestellenabschnitt zwischen dem Hauptbahnhof und der Ebertstraße bedingt. Um 5 Uhr beträgt die durchschnittliche Haltedauer an der Haltestelle Ebertstraße 27 Sekunden, um 11 Uhr 32 Sekunden. Für den Abschnitt sind im Fahrplan lediglich 60 Sekunden bei einer Streckenlänge von 338 Metern vorgesehen. Abzüglich der Haltedauern ist es daher fahrdynamisch nicht möglich, bei Einhaltung der Geschwindigkeitsbeschränkungen die Haltestelle Ebertstraße pünktlich zu erreichen. [212]

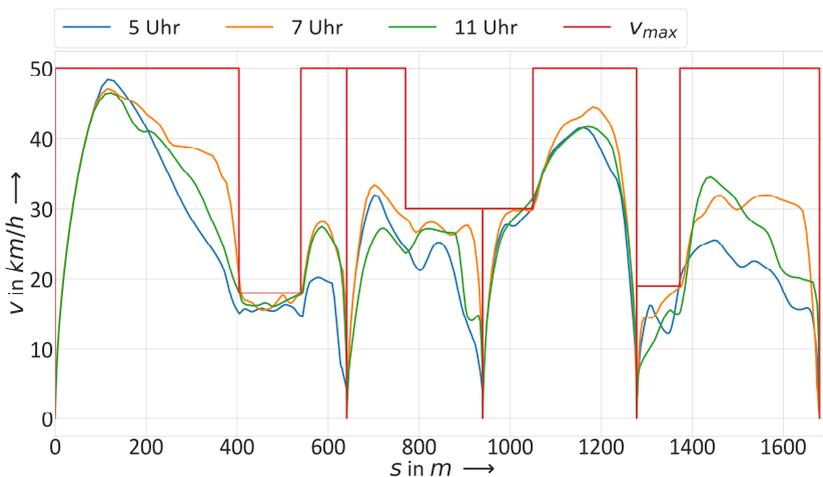


Abbildung 6.10: Fahrprofile der trainierten Deep-RL-Agenten im ersten Szenario zwischen Tivoli und Kolpingplatz nach Tesar [212]

Tabelle 6.4: Energiebedarf und Fahrplanabweichung der trainierten Agenten des ersten Szenarios nach Tesar [212]

	Energiebedarf	Fahrplanabweichung
Szenario 1: 5 Uhr	2,64 kWh	17 s
Szenario 1: 7 Uhr	2,96 kWh	52 s
Szenario 1: 11 Uhr	2,69 kWh	19 s

Insofern an einer Haltestelle eine Fahrplanabweichung aufgetreten ist, kann diese in den folgenden Haltestellenabschnitten nicht mehr kompensiert werden. Die Agenten können lediglich durch ihre Fahrweise sicherstellen, dass in weiteren Haltestellenabschnitten keine weitere Fahrplanabweichung akkumuliert wird. Der vierte Haltestellenabschnitt umfasst eine Länge von 402 Metern und die im Fahrplan vorgesehene Fahrzeit liegt bei 120 Sekunden (vgl. Tabelle 6.1), wodurch eine Fahrzeitreserve vorhanden ist, aufgrund derer die Agenten die Haltestelle Kolpingplatz durch ihre gewählten Fahrprofile pünktlich erreichen.

6.2.2 Training Szenario 2

In Abbildung 6.11 sind die Fahrprofile der besten Agenten für das zweite Szenario zu den jeweiligen Verkehrszeiten dargestellt. Für jede der drei ausgewählten Verkehrszeiten wurden 21 Agenten trainiert und der Agent mit dem höchsten Reward ausgewählt. Die Fahrprofile zwischen den drei Verkehrszeiten sind aufgrund der ähnlich ausgeprägten Haltedauern im zweiten Szenario wesentlich einheitlicher als im ersten Szenario. Abhängig von den jeweiligen Verkehrszeiten werden die Geschwindigkeiten angepasst. Im ersten Haltestellenabschnitt zwischen der Glogauer Straße und der Haltestelle Waldstadt-Zentrum liegt nach Abbildung 6.7 um 11 Uhr eine Haltedauer von 23 Sekunden vor. Diese Haltedauer ist höher als zu den beiden anderen Verkehrszeiten, weshalb die Geschwindigkeitstrajektorie des 11 Uhr-Agenten angepasst wird. Im vierten und fünften Haltestellenabschnitt sind aufgrund der im Fahrplan vorgesehenen Fahrzeiten und der Haltedauern an der Haltestelle keine hohen Geschwindigkeiten für ein pünktliches Erreichen nötig. Der vierte Haltestellenabschnitt zwischen der Elbinger Straße und der Osteroder Straße ist 574 Meter lang und im Fahrplan vorgesehen ist eine Fahrzeit von 120 Sekunden. Der fünfte Haltestellenabschnitt bis zur Endhaltestelle Europäische Schule ist lediglich 209 Meter lang und aufgrund der eingeplanten Standzeit in der Wendeschleife können die vollen, im Fahrplan vorgesehenen, 60 Sekunden genutzt werden. Zur Steigerung der Energieeffizienz reduzieren die Agenten auf diesen beiden

Streckenabschnitten daher die Durchschnittsgeschwindigkeit, da eine Fahrzeitreserve vorhanden ist.

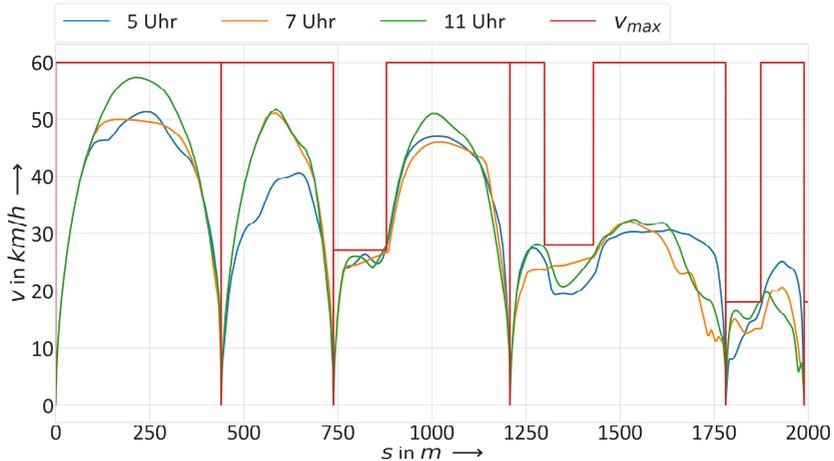


Abbildung 6.11: Fahrprofile der trainierten Deep-RL-Agenten im zweiten Szenario zwischen der Glogauer Straße und der Haltestelle Waldstadt Europäische Schule nach Tesar [212]

Tabelle 6.5 zeigt die Fahrplanabweichungen sowie die Energiebedarfe der drei trainierten Agenten für die drei Verkehrszeiten des zweiten Szenarios. Die Fahrplanabweichungen der drei trainierten Agenten weichen durch die Ähnlichkeit der Verkehrszeiten nicht stark voneinander ab. Aufgrund der höheren Geschwindigkeiten zur Einhaltung der Pünktlichkeit des 11 Uhr-Agenten liegt dessen Energiebedarf knapp 6 % über dem der beiden weiteren Agenten. Die ähnliche Ausprägung der Fahrplanabweichungen der drei Verkehrszeiten liegen an den gleichmäßigen Haltedauern nach Abbildung 6.7. [212]

Tabelle 6.5: Energiebedarf und Fahrplanabweichung der trainierten Agenten des zweiten Szenarios nach Tesar [212]

	Energiebedarf	Fahrplanabweichung
Szenario 2: 5 Uhr	3,26 kWh	22 s
Szenario 2: 7 Uhr	3,23 kWh	15 s
Szenario 2: 11 Uhr	3,47 kWh	24 s

6.3 Vergleich zwischen Deep Reinforcement Learning, Dynamic Programming und Fahrern

Nach dem Training der Agenten auf beiden Szenarien zu den verschiedenen Verkehrszeiten werden die Fahrprofile mit einem theoretischen Optimum und Fahrern aus dem regulären Fahrgastbetrieb verglichen.

6.3.1 Optimalsteuerung mit Dynamic Programming

Zur Ermittlung eines theoretischen Optimums wird Dynamic Programming nach Kapitel 2.2 verwendet. Anhand des berechneten Optimums kann abgeschätzt werden, wie viel Verbesserungspotential in den Fahrprofilen der KI noch liegt. Vergleichbar wird Dynamic Programming von Eller [59] eingesetzt, um ein theoretisches Optimum als Benchmark für die Optimierungsalgorithmen zu berechnen.

Um Dynamic Programming anwenden zu können und gleichzeitig in einer vertretbaren Berechnungsdauer ein Ergebnis zu ermitteln, werden Anpassungen des Aktions- und Lösungsraums vorgenommen. Zunächst muss der Aktionsraum nach Abbildung 6.12 (a) diskretisiert werden, da mit einem kontinuierlichen Aktionsraum keine Konvergenz der Optimierung sichergestellt werden kann. Sowohl für positive als auch negative Beschleunigungen sind fünf diskrete Beschleunigungen wählbar. Zudem gibt es einen Zustand mit einer Beschleunigung von 0 m/s^2 über den gesamten Geschwindigkeitsbereich.

In einem weiteren Schritt wird zur Steigerung der Berechnungszeit die Auswahl der möglichen Beschleunigungen in Abhängigkeit des aktuellen Zustands nach Abbildung 6.12 (b) eingeschränkt. Ausgehend vom Zustand zum Zeitpunkt t kann zum Zeitpunkt $t + 1$ lediglich der nächsthöhere, der darunterliegende oder der aktuelle Zustand gewählt werden.

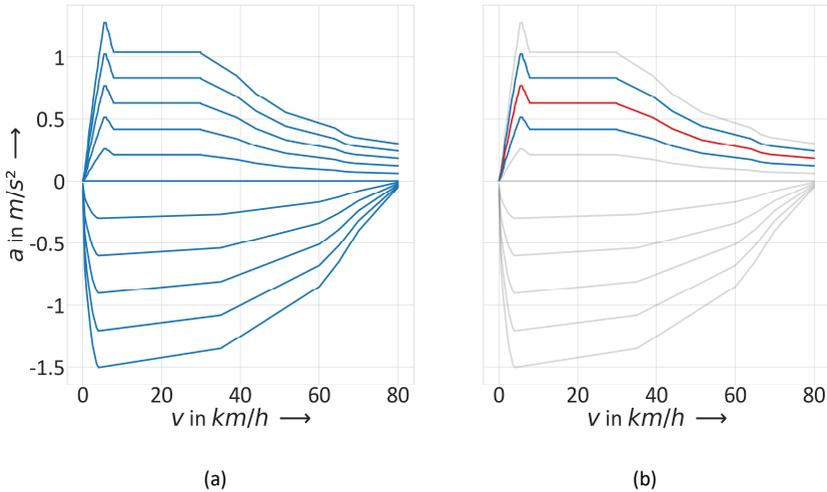


Abbildung 6.12: Diskretisierung des Aktionsraums in fünf positive, fünf negative und eine neutrale Beschleunigungsmöglichkeit (a) und Änderungsmöglichkeiten der Beschleunigung (b).

Aufgrund von Fahrzeiten von mehr als 100 Sekunden kann selbst mit lediglich drei möglichen Zuständen kein Optimum in einer vertretbaren Zeit berechnet werden. Daher wird der Lösungsraum nach Abbildung 6.13 beispielhaft für das erste Szenario zur Verkehrszeit um 11 Uhr mit oberen und unteren Geschwindigkeitsbändern eingeschränkt. Dieser Einschränkung liegt die Annahme zugrunde, dass die Fahrprofile der KI bereits nahe am theoretischen Optimum liegen. Standardmäßig wird ein Geschwindigkeitsbereich von $\pm 3 \text{ km/h}$ um die Geschwindigkeitstrajektorie der KI gelegt. In Bereichen, in

welchen die drei ermittelten Fahrprofile der jeweiligen Verkehrszeiten stärker divergieren, wird der Lösungsraum erweitert. In der Anfahrphase bis zum Streckenmeter 100 zeigt sich ein einheitliches Bild, weswegen das Band eng gewählt ist. Im Bereich zwischen 100 und 400 Metern wird das Band geweitet, um Freiräume bei der Optimierung zu gewährleisten. Ebenso wird dies im vierten Haltestellenabschnitt umgesetzt.

Eine weitere Besonderheit stellt der dritte Haltestellenabschnitt dar. Sämtliche trainierte Agenten erreichen nach den Ergebnissen in Kapitel 6.2 verspätet die Haltestelle Eberstraße. Daher wird das untere Band eng gewählt und nach oben viel Freiraum gelassen, um die Verspätung möglichst zu reduzieren.

Durch die Geschwindigkeitsbänder entstehen in der Folge Anforderungen, bis zu welcher Zeit ein Streckenmeter erreicht sein muss, oder maximal erreicht sein darf. Dadurch werden frühzeitig Fahrprofile aussortiert und die Berechnungsdauer gesteigert. Das Vorgehen wird in dieser Form für sämtliche weitere Verkehrszeiten sowie das zweite Szenario umgesetzt.

Ein ermitteltes Fahrprofil durch Dynamic Programming für das erste Szenario zur Nebenverkehrszeit um 11 Uhr ist in Abbildung 6.14 dargestellt. In den ersten beiden Haltestellenabschnitten ist dieses ähnlich zu dem von der KI ermittelten Fahrprofil. Im dritten Abschnitt vom Hauptbahnhof bis zur Eberstraße wird durch Dynamic Programming das Geschwindigkeitsprofil so angepasst, dass die Verspätung durch die erhöhte Geschwindigkeit reduziert wird. Im vierten Abschnitt ist eine hohe Fahrzeitreserve vorhanden, so dass ein verbessertes Fahrprofil mit einer geringeren maximalen Geschwindigkeit und damit einer höheren Energieeffizienz ermittelt wird. Trotz der gewählten Einschränkungen des Lösungsraums liegt die Berechnungsdauer des Fahrprofils allein für den vierten Haltestellenabschnitt bei mehr als drei Tagen. Diese langen Berechnungsdauern schließen Dynamic Programming als Verfahren für den Einsatz in Assistenzsystemen aus.

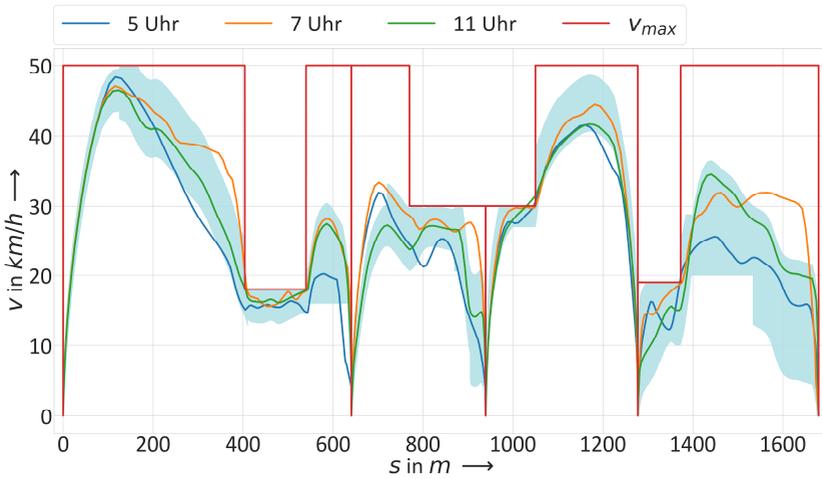


Abbildung 6.13: Eingrenzung des Lösungsraums für Dynamic Programming durch Implementierung einer oberen und unteren Schranke

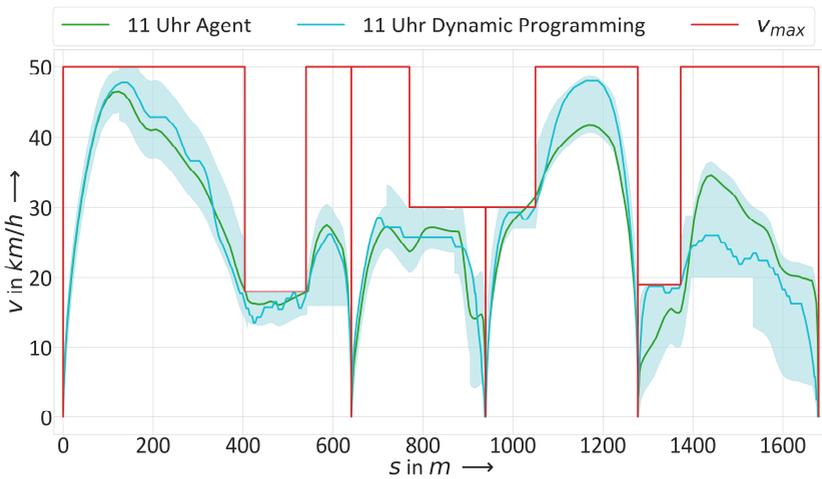


Abbildung 6.14: Durch Dynamic Programming ermitteltes Fahrprofil für die Nebenverkehrszeit des ersten Szenarios innerhalb der Grenzen

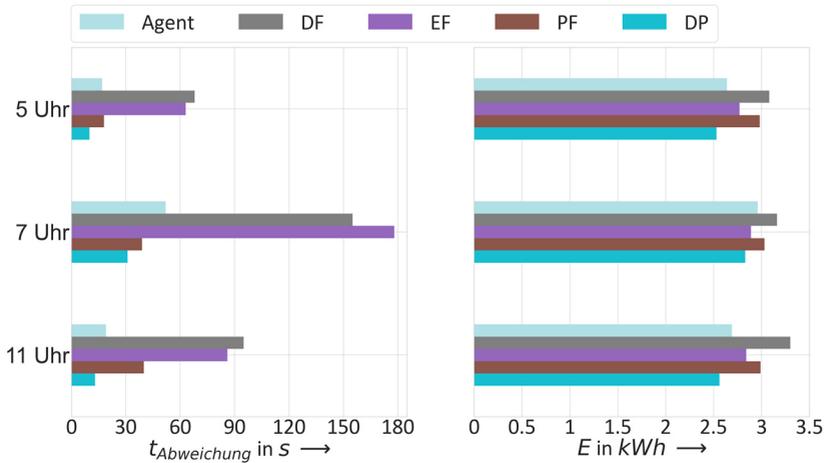
6.3.2 Vergleich von Energieeffizienz und Pünktlichkeit zwischen KI, Dynamic Programming und Fahrern

Zur Einordnung der Fahrprofile der KI werden diese mit Fahrern aus dem regulären Fahrgastbetrieb und einem durch Dynamic Programming (DP) ermittelten theoretischen Optimum für die jeweilige Verkehrszeit in den Szenarien 1 und 2 verglichen. Fahrertypen werden in drei verschiedene Klassen aufgeteilt. Für jede Verkehrszeit in den beiden Szenarien wird aus allen Fahrprofilen ein durchschnittlicher Fahrer (DF) ermittelt. Zudem werden noch der energieeffizienteste Fahrer (EF) sowie der pünktlichste Fahrer (PF) zum Vergleich hinzugezogen. Als Vergleichsgrößen dienen die Fahrplanabweichung und der Energiebedarf. Für beide Szenarien wird zudem die Auswirkung einer veränderten Reward-Funktion mit einer erhöhten Gewichtung auf die Energieeffizienz untersucht. Diese Auswertung befindet sich in Anhang A.3.

Szenario 1

In Abbildung 6.15 (a) ist die Fahrplanabweichung $t_{\text{Abweichung}}$ der jeweils trainierten Deep-RL-Agenten mit den Fahrprofilen der drei Fahrertypen und Dynamic Programming dargestellt. Abbildung 6.15 (b) zeigt den Energiebedarf der jeweiligen Fahrprofile zu den drei Verkehrszeiten. Die exakten Werte zur Fahrplanabweichung und zur Energieeffizienz sind in Tabelle 6.6 aufgelistet. Zu erkennen ist, dass die trainierte KI grundsätzlich bessere Fahrprofile hinsichtlich der Zielkriterien als Fahrer aus dem regulären Fahrgastbetrieb wählt. Gegenüber den durchschnittlichen Fahrern sind Verbesserungen in Pünktlichkeit und Energieeffizienz stets gegeben. Für die Verkehrszeiten um 5 Uhr und 11 Uhr steigern die Fahrprofile der KI Energieeffizienz und Pünktlichkeit verglichen mit allen Fahrertypen. Zur Hauptverkehrszeit um 7 Uhr weist der pünktlichste Fahrer ein Fahrprofil mit einer um 13 Sekunden geringeren Fahrplanabweichung und der energieeffizienteste Fahrer ein Profil mit einem um 0,07 kWh geringerem Energiebedarf auf. Der Vergleich mit den pünktlichsten und energieeffizientesten Fahrern beruht jedoch stets auf einer Stichprobe

von $n = 1$. Dabei gelten nicht zwingend die gleichen betrieblichen Randbedingungen wie beim Training der Agenten und der durchschnittlichen Fahrer. [212]



(a) Fahrplanabweichungen von KI, Fahrertypen und Dynamic Programming

(b) Energiebedarfe von KI, Fahrertypen und Dynamic Programming

Abbildung 6.15: Vergleich von KI, Fahrertypen und Dynamic Programming im ersten Szenario zu den drei Verkehrszeiten nach Tesar [212]

Tabelle 6.6: Fahrplanabweichungen und Energiebedarfe der verschiedenen Fahrertypen und Dynamic Programming des ersten Szenarios nach Tesar [212]

	Fahrplanabweichung [s]				Energiebedarf [kWh]			
	DF	EF	PF	DP	DF	EF	PF	DP
5 Uhr	68	63	18	10	3,08	2,77	2,98	2,56
7 Uhr	155	178	39	31	3,16	2,89	3,03	2,87
11 Uhr	95	86	40	13	3,30	2,84	2,99	2,61

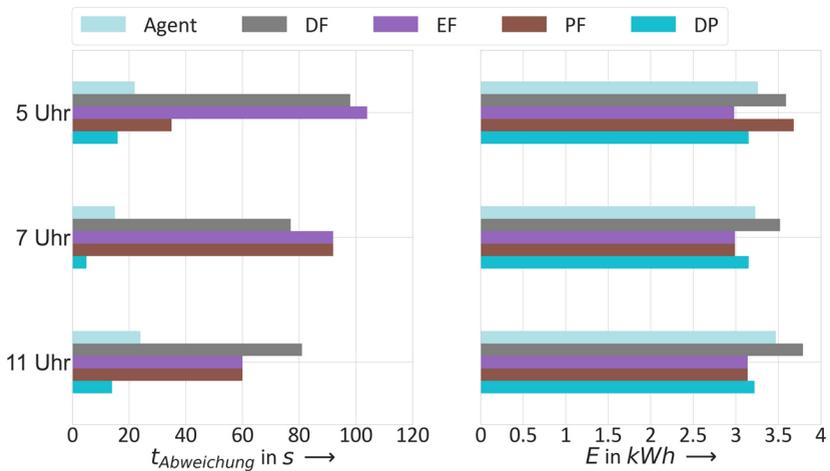
Über die drei Verkehrszeiten gemittelt können die trainierten Deep-RL-Agenten (vgl. Tabelle 6.4) durch das verbesserte Fahrprofil die Fahrplanabweichung gegenüber den durchschnittlichen Fahrern um 65 Sekunden reduzieren und 0,42 kWh Energie einsparen. Dies entspricht einer Energieeinsparung von 13,6 %. Im Vergleich zu den energieeffizientesten Fahrern für die jeweiligen Verkehrszeiten kann die Fahrplanabweichung sogar um 80 Sekunden und der Energiebedarf um weitere 0,07 kWh gesenkt werden. Prozentual entspricht dies einer Einsparung von 2,5 %. Im Vergleich zu den pünktlichsten Fahrern wird die Fahrplanabweichung um 3 Sekunden und der Energiebedarf um 0,24 kWh über die Verkehrszeiten reduziert. Dies entspricht einem verringerten Energiebedarf um 8 %. [212]

Die durch Dynamic Programming ermittelten Fahrprofile weisen im Gegensatz zu den Fahrprofilen der KI noch ein geringes Verbesserungspotential auf. Durch Dynamic Programming kann im Mittel die Fahrplanabweichung um weitere 11 Sekunden und der Energiebedarf um 0,12 kWh im Gegensatz zu den trainierten Deep-RL-Agenten reduziert werden. Diese Einsparung entspricht einer Verringerung um 4,3 %. [212]

Szenario 2

Vergleichbar zum ersten Szenario werden in Abbildung 6.16 (a) die Fahrplanabweichung der jeweils trainierten Deep-RL-Agenten (vgl. Tabelle 6.5) mit den Fahrprofilen der drei Fahrertypen und Dynamic Programming dargestellt. Abbildung 6.16 (b) zeigt den Energiebedarf der jeweiligen Fahrprofile zu den drei Verkehrszeiten. Die exakten Werte zur Fahrplanabweichung und zur Energieeffizienz sind in Tabelle 6.7 aufgelistet.

Im zweiten Szenario ist die trainierte KI zu jeder Verkehrszeit pünktlicher als alle drei Fahrertypen. Verglichen mit dem durchschnittlichen Fahrer kann ebenfalls die Energieeffizienz über alle drei Verkehrszeiten gesteigert werden. Gemessen an den energieeffizientesten Fahrern schneidet die KI jedoch hinsichtlich des Energiebedarfs zu jeder Verkehrszeit schlechter ab. Zu den Verkehrszeiten um 7 Uhr und 11 Uhr gibt es den Sonderfall, dass der energieeffizienteste Fahrer auch gleichzeitig der pünktlichste Fahrer ist. [212]



(a) Fahrplanabweichungen von KI, Fahrertypen und Dynamic Programming

(b) Energiebedarfe von KI, Fahrertypen und Dynamic Programming

Abbildung 6.16: Vergleich von KI, Fahrertypen und Dynamic Programming im zweiten Szenario zu den drei Verkehrszeiten nach Tesar [212]

Tabelle 6.7: Fahrplanabweichungen und Energiebedarfe der verschiedenen Fahrertypen und Dynamic Programming des zweiten Szenarios nach Tesar [212]

	Fahrplanabweichung [s]				Energiebedarf [kWh]			
	DF	EF	PF	DP	DF	EF	PF	DP
5 Uhr	98	104	35	16	3,59	2,97	3,68	3,15
7 Uhr	77	92	92	5	3,52	2,99	2,99	3,15
11 Uhr	81	60	60	14	3,79	3,14	3,14	3,22

Über die drei Verkehrszeiten gemittelt kann die trainierte KI durch das verbesserte Fahrprofil die Fahrplanabweichung gegenüber den durchschnittlichen Fahrern um 65 Sekunden reduzieren. Der Energiebedarf ist 0,31 kWh geringer, was einer Einsparung von 8,5 % entspricht. Verglichen mit den ener-

gieffizientesten Fahrern kann die Fahrplanabweichung ebenfalls um 65 Sekunden reduziert werden. Allerdings ist der Energiebedarf der Deep-RL-Agenten um 0,28 kWh höher, was einem zusätzlichen Energiebedarf von 9,2 % entspricht. Im Vergleich zum pünktlichsten Fahrer kann die Fahrplanabweichung um 42 Sekunden verringert werden. Der Energiebedarf der Fahrprofile der KI liegt jedoch um 0,11 kWh höher, was zu einem Mehrbedarf von 3,3 % führt. [212]

Wie im ersten Szenario führen die durch Dynamic Programming ermittelten Fahrprofile zu geringen Verbesserungen im Vergleich zur trainierten KI. Im Mittel kann die Fahrplanabweichung durch Dynamic Programming um 9 Sekunden und der Energiebedarf um 0,15 kWh (4,3 %) reduziert werden. Zu allen drei Verkehrszeiten weisen die Fahrprofile des energieeffizientesten Fahrers einen geringeren Energiebedarf als Dynamic Programming auf. Dynamic Programming optimiert aufgrund der gegebenen Rewardfunktion aus Kapitel 5.5 vorrangig auf die Pünktlichkeit, weshalb der erhöhte Energiebedarf auf die pünktlichere Fahrweise zurückzuführen ist. Gegenüber den energieeffizientesten Fahrern reduziert Dynamic Programming die Fahrplanabweichung wiederum um durchschnittlich 74 Sekunden. [212]

6.3.3 Klassifikation der Fahrprofile der trainierten KI

Zur weiteren Einordnung der Fahrprofile werden diese anhand des in Kapitel 4.3 trainierten Klassifikators klassifiziert.

Szenario 1

In Abbildung 6.17 (a) wird der Traktionsenergiebedarf über die Fahrzeit im ersten Szenario aufgetragen. Zur besseren Einordnung über den gesamten Tag sind sämtliche Fahrten von 5 Uhr bis 23 Uhr auf dem Streckenabschnitt hinterlegt. Angelehnt an Abbildung 3.2 liegen die drei Fahrprofile der KI zu den jeweiligen Verkehrszeiten auf der Pareto-Front. Abbildung 6.17 (b) zeigt den Energiebedarf über den Coasting-Anteil. Die Coasting-Anteile der KI sind

geringer als die der Fahrprofile der Fahrer aus dem regulären Fahrgastbetrieb. Zur Verkehrszeit um 5 Uhr wird ein Coasting-Anteil von 19,8 %, um 7 Uhr von 20,0 % und um 11 Uhr von 20,7 % berechnet. Zum einen liegt das an der pünktlichkeitsorientierten Fahrweise. Zum anderen wird im zweiten und vierten Haltestellenabstand nach Abbildung 6.10 Coasting nicht konsequent genug umgesetzt, wo es die Fahrzeitreserven zulassen würden. Um einen höheren Coasting-Anteil zu erreichen könnte die Klassifikation in das Deep-RL-System integriert werden. Durch einen weiteren Reward auf erfolgreiches Coasting könnten die Agenten beim Erlernen noch energieeffizienterer Fahrstrategien unterstützt werden.

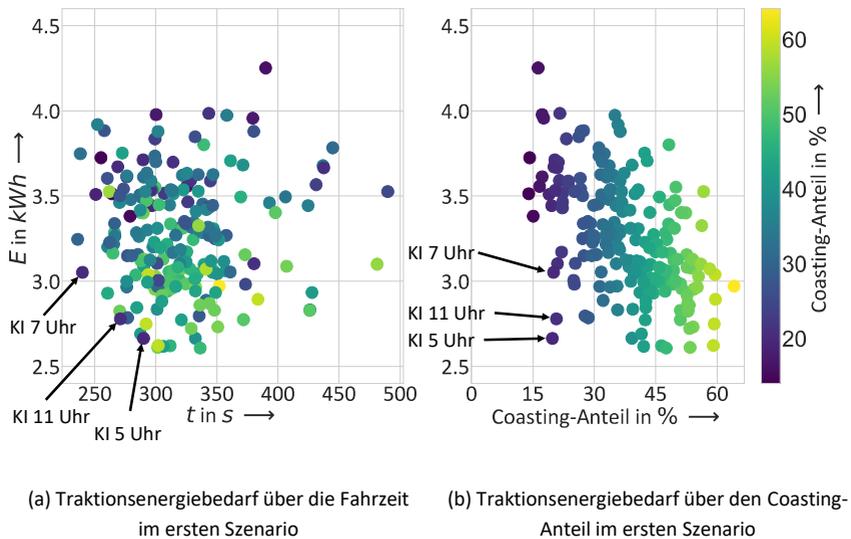


Abbildung 6.17: Klassifikation der Fahrweise der KI im Vergleich zu Fahrprofilen von Fahrern aus dem regulären Fahrgastbetrieb im ersten Szenario

Szenario 2

In Abbildung 6.18 (a) ist der Traktionsenergiebedarf über die Fahrzeit im zweiten Szenario dargestellt. Zur besseren Einordnung über den gesamten Tag

sind für das zweite Szenario ebenfalls sämtliche Fahrten von 5 Uhr bis 23 Uhr auf dem Streckenabschnitt hinterlegt. Das Bild ist weniger klar als im ersten Szenario. Die Fahrplanabweichung konnte im Gegensatz zu den Fahrern aus dem regulären Fahrgastbetrieb nach 6.3.2 verbessert werden, dennoch gibt es Fahrprofile, die energieeffizienter und in geringerer Zeit gefahren werden. Dies ist bedingt durch die strikte Einhaltung der im Fahrplan vorgegebenen Zeiten durch die KI. Durch schnellere Fahrten im vierten und fünften Haltestellenabschnitt wird die Fahrzeit reduziert. Diese kürzeren Fahrzeiten sind nicht durch Verspätungen aus der bisherigen Fahrt bis zur Glogauer Straße bedingt.

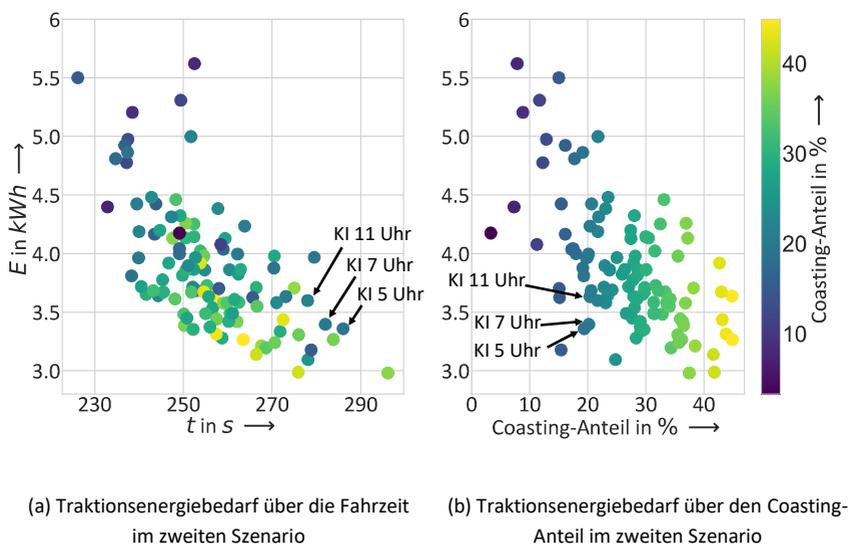


Abbildung 6.18: Klassifikation der Fahrweise der KI im Gegensatz zu Fahrprofilen von Fahrern aus dem regulären Fahrgastbetrieb im zweiten Szenario

Abbildung 6.18 (b) zeigt die Coasting-Anteile der einzelnen Fahrprofile auf dem Streckenabschnitt. Wie im ersten Szenario weist die KI keine hohen Coasting-Anteile auf. Zur Verkehrszeit um 5 Uhr wird ein Coasting-Anteil von

20,2 %, um 7 Uhr von 19,4 % und um 11 Uhr von 21,7 % berechnet. Speziell auf den letzten beiden Haltestellenabschnitten könnte der Coasting-Anteil noch erhöht werden. Dadurch könnte zusätzlich der Energiebedarf reduziert werden.

6.4 Auswertung Deep Reinforcement Learning Agent auf unbekanntem Szenarien

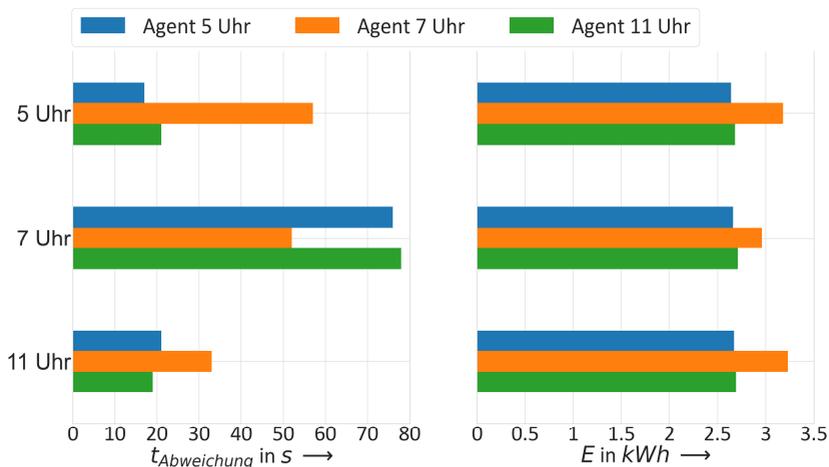
In Kapitel 6.3 konnte gezeigt werden, dass Deep-RL-Agenten zu ihren explizit trainierten Verkehrszeiten die Pünktlichkeit und Energieeffizienz gegenüber Fahrern aus dem regulären Fahrgastbetrieb steigern. Haltedauern weichen über den gesamten Tag jedoch wesentlich voneinander ab. Daher muss die KI in der Lage sein, ohne weiteres Training durch das aufgebaute Verständnis von Fahrzeug, Betrieb und Infrastruktur energieeffiziente und pünktliche Fahrprofile zu ermitteln. Hierfür werden die trainierten Deep-RL-Agenten auf allen Haltedauern von 5 bis 23 Uhr getestet und hinsichtlich ihrer Generalisierungsfähigkeiten untersucht. Kapitel 6.4.1 vergleicht die untrainierten Haltedauern in Szenario 1, Kapitel 6.4.2 umfasst den Vergleich für das zweite Szenario.

6.4.1 Vergleich untrainierter Haltedauern in Szenario 1

Im ersten Schritt werden die drei Agenten auf den jeweils drei trainierten Verkehrszeiten ausgewertet. Danach wird jeder trainierte Agent mit den anderen beiden nicht für diese Verkehrszeiten trainierten Agenten verglichen. Der Vergleich von Fahrplanabweichung und Energiebedarf ist in Abbildung 6.19 dargestellt. Für die jeweilige Verkehrszeit sind die Ergebnisse der drei Agenten aufgetragen. In keinem Fall weist ein Agent in einer untrainierten Verkehrszeit geringere Fahrplanabweichungen als der trainierte Agent auf. Zur Verkehrszeit um 7 Uhr gelingt es jedoch den beiden untrainierten 5 Uhr- und 7 Uhr-Agenten den Energiebedarf zu verbessern. Der 7 Uhr-Agent wählt zu jeder Verkehrszeit das Fahrprofil mit dem höchsten Energiebedarf.

Im Durchschnitt über die drei Verkehrszeiten beträgt die Fahrplanabweichung des 5 Uhr-Agenten 38 Sekunden und der Energiebedarf 2,66 kWh. Der 11 Uhr-Agent zeigt mit einer durchschnittlichen Verspätung von 40 Sekunden und einem Energiebedarf von 2,69 kWh vergleichbare Ergebnisse. Lediglich der 7 Uhr-Agent fällt mit einer Fahrplanabweichung von 47 Sekunden und einem durchschnittlichen Energiebedarf von 3,12 kWh ab.

Mögliche Gründe der schlechteren Generalisierung durch den 7 Uhr-Agenten liegen im Training eines herausfordernden Szenarios, in welchem der Fokus auf Fahrprofilen mit minimaler Fahrzeit liegt. Dadurch fällt es dem Agenten schwer, in anderen Szenarien die Geschwindigkeit zu reduzieren, weshalb dieser mehrere Haltestellen zu früh erreicht.



(a) Fahrplanabweichungen der Agenten zu den drei Verkehrszeiten

(b) Energiebedarfe der Agenten zu den drei Verkehrszeiten

Abbildung 6.19: Fahrplanabweichungen und Energiebedarfe der Fahrprofile der Agenten zu trainierten und untrainierten Verkehrszeiten im ersten Szenario

Im zweiten Schritt werden die Agenten zu allen Haltezeiten von 5 bis 23 Uhr nach Abbildung 6.4 getestet. Die durchschnittliche Fahrplanabweichung über

die Haltedauern der drei Agenten und der drei Fahrertypen ist in Abbildung 6.20 (a) dargestellt. Den Vergleich des Traktionsenergiebedarfs zeigt Abbildung 6.20 (b). Einen Überblick über die Fahrplanabweichung und den Energiebedarf der Fahrprofile zu den einzelnen Haltedauern geben Tabellen A.3 und A.4 in Anhang A.5.

Die besten Generalisierungsfähigkeiten außerhalb des trainierten Szenarios weist der 5 Uhr-Agent mit einer Fahrplanabweichung von 27 Sekunden und einem Energiebedarf von 2,73 kWh auf. Vergleichbar generalisiert der 11 Uhr-Agent mit einer Fahrplanabweichung von 32 Sekunden und einem Energiebedarf von 2,75 kWh. Über alle Haltedauern hinweg fällt der 7 Uhr-Agent mit einer Fahrplanabweichung von 38 Sekunden und einem Energiebedarf von 3,11 kWh wieder gegenüber den anderen beiden Agenten ab. [212]

Im Vergleich zu den drei Fahrertypen kann der 5 Uhr-Agent als beste Referenz die Fahrplanabweichung gegenüber den durchschnittlichen Fahrern um 95 Sekunden reduzieren. Die Vorteile verglichen mit den energieeffizientesten Fahrern liegen bei 98 Sekunden, bei den pünktlichsten Fahrern ergibt sich eine Reduzierung der Fahrplanabweichung um 11 Sekunden. Durch den 5 Uhr-Agenten kann ebenfalls der Energiebedarf gegenüber allen Fahrertypen reduziert werden. Verglichen mit den durchschnittlichen Fahrern wird der Energiebedarf um 0,53 kWh (-19 %) verringert. Selbst gegenüber den energieeffizientesten Fahrern werden 0,03 kWh (-1,1 %) eingespart. Im Vergleich zu den pünktlichsten Fahrern ergibt sich eine Reduzierung um 0,44 kWh (-16,1 %). Es zeigt sich, dass Agenten besser generalisieren, wenn sie in ihrem ursprünglichen Trainingsszenario sowohl Abschnitte mit positiven als auch negativen Fahrzeitreserven vorfinden. Der 7 Uhr-Agent musste im Training stets hohe Geschwindigkeiten wählen, um die Verspätung zu reduzieren. Bei der Untersuchung zu anderen Haltedauern kommt der 7 Uhr-Agent häufig zu früh an der Haltestelle an und schöpft dabei das Potential zur Steigerung der Energieeffizienz nicht aus. [212]

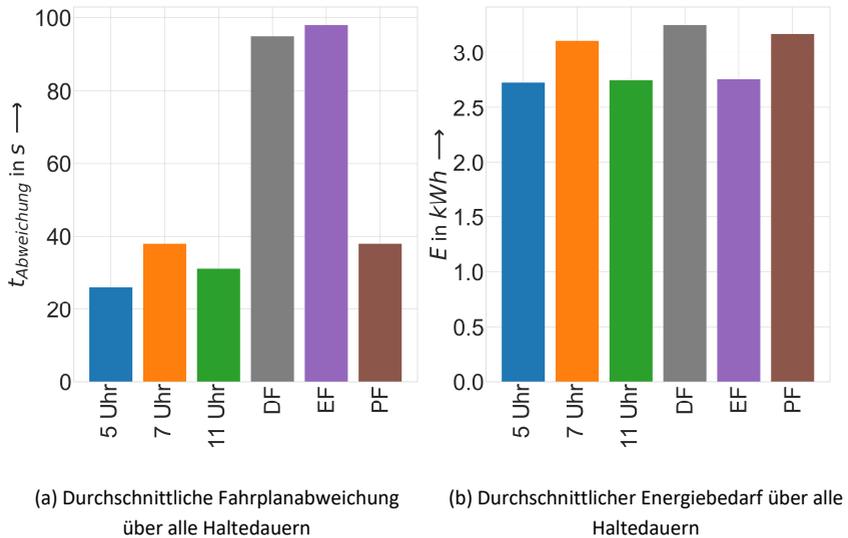


Abbildung 6.20: Fahrplanabweichungen und Energiebedarfe der Fahrprofile der Agenten und Fahrertypen über alle Haltedauern von 5 bis 23 Uhr im ersten Szenario nach Tesar [212]

6.4.2 Vergleich untrainierter Haltedauern in Szenario 2

Entsprechend zum ersten Szenario werden im zweiten Szenario ebenfalls zunächst die trainierten Agenten zu den beiden untrainierten Verkehrszeiten getestet und mit den trainierten Agenten verglichen. Fahrplanabweichung und Energiebedarf zu den drei Verkehrszeiten der drei Agenten sind in Abbildung 6.21 dargestellt. Erneut kann die Fahrplanabweichung in keinem Fall durch einen untrainierten Agenten verringert werden. Zur Verkehrszeit um 11 Uhr gelingt es jedoch dem untrainierten 7 Uhr-Agenten ein Fahrprofil mit höherer Energieeffizienz zu wählen.

Im Durchschnitt über die drei Verkehrszeiten beträgt die Fahrplanabweichung des 5 Uhr-Agenten 23 Sekunden und der Energiebedarf 3,4 kWh. Der 11 Uhr-Agent akkumuliert durchschnittlich ebenfalls eine Fahrplanabweichung von 23 Sekunden bei einem Energiebedarf von 3,46 kWh. Der 7 Uhr-

Agent weist eine vergleichbare Fahrplanabweichung von 26 Sekunden auf, benötigt jedoch durchschnittlich nur 3,25 kWh an Energie.

Die Generalisierung ist im zweiten Szenario weniger herausfordernd für die einzelnen Agenten, da die Haltedauern nach Abbildung 6.7 wesentlich einheitlicher sind.

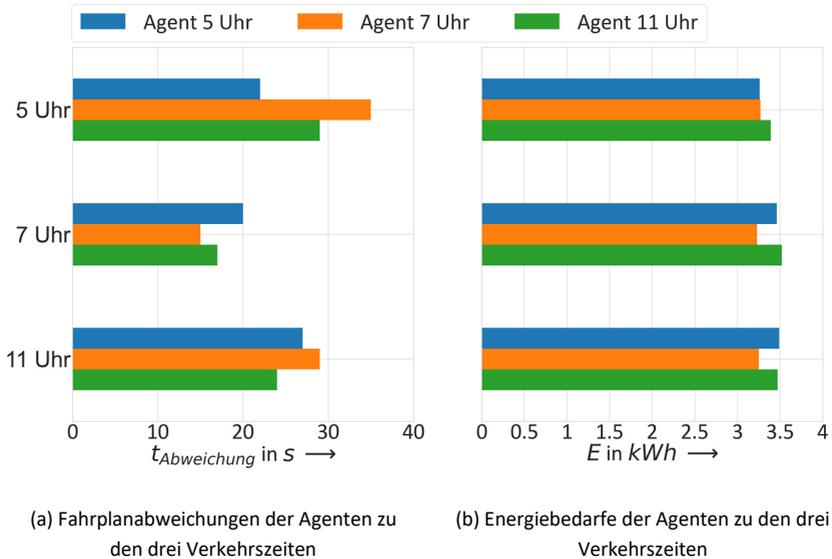


Abbildung 6.21: Fahrplanabweichungen und Energiebedarfe der Fahrprofile der Agenten zu trainierten und untrainierten Verkehrszeiten im zweiten Szenario

Im zweiten Schritt werden die Agenten erneut zu allen Haltedauern von 5 bis 23 Uhr nach Abbildung 6.7 getestet. Die durchschnittliche Fahrplanabweichung über die Haltedauern der drei Agenten und der drei Fahrertypen ist in Abbildung 6.22 (a) dargestellt. Den Vergleich des Traktionsenergiebedarfs zeigt Abbildung 6.22 (b). Einen Überblick über die Fahrplanabweichung und den Energiebedarf der Fahrprofile zu den einzelnen Haltedauern geben Tabellen A.5 und A.6 in Anhang A.4.

Im Gegensatz zum ersten Szenario gibt es keinen Agenten, welcher sowohl

hinsichtlich der Fahrplanabweichung als auch des Energiebedarfs die besten Generalisierungsfähigkeiten zeigt. Über alle Haltedauern weist der 5 Uhr-Agent eine durchschnittliche Fahrplanabweichung von 24 Sekunden bei einem Energiebedarf von 3,43 kWh auf. Der 11 Uhr-Agent zeigt mit einer Fahrplanabweichung von 24 Sekunden und einem Energiebedarf von 3,47 kWh vergleichbare Ergebnisse. Im Vergleich dazu akkumuliert der 7 Uhr-Agent 27 Sekunden an Fahrplanabweichung über die gesamte Strecke bei einem reduzierten Energiebedarf von 3,27 kWh. [212]

Als Vergleichswert zu den drei Fahrertypen dient der 7 Uhr-Agent, da dieser bei einer vergleichbaren Fahrplanabweichung den Energiebedarf reduzieren kann. Der 7 Uhr-Agent reduziert die durchschnittliche Fahrplanabweichung über alle Haltedauern gegenüber den durchschnittlichen Fahrern um 56 Sekunden und den Energiebedarf um 0,62 kWh (-18,9 %). Im Vergleich zu den energieeffizientesten Fahrern wird die Fahrplanabweichung um 72 Sekunden und der Energiebedarf um 0,03 kWh (-0,9 %) verringert. Gegenüber den pünktlichsten Fahrern nimmt die Fahrplanabweichung um 48 Sekunden und der Energiebedarf um 0,37 kWh (-11,3 %) ab. [212]

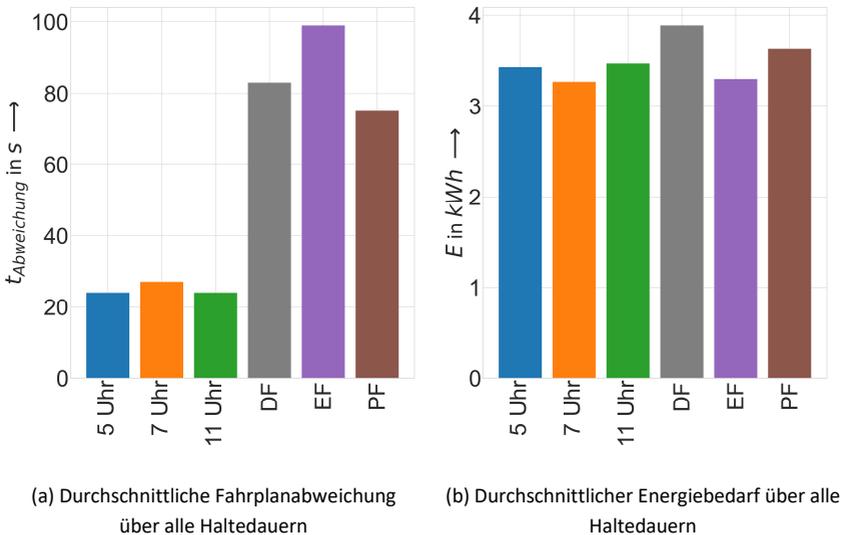


Abbildung 6.22: Fahrplanabweichungen und Energiebedarfe der Fahrprofile der Agenten und Fahrertypen über alle Haltezeiten von 5 bis 23 Uhr im zweiten Szenario nach Tesar [212]

6.5 Deep Reinforcement Learning Agent auf unbekanntem Streckenabschnitten

Während des täglichen Betriebs können aufgrund von Störungen unplanmäßige Umleitungsfahrten auf unbekanntem Streckenabschnitten auftreten. Stellvertretend für eine Umleitungsfahrt wird das dritte Szenario von der Haltestelle Durlacher Tor bis zum Tivoli betrachtet.

Ohne weiteres Training werden die Agenten des ersten und zweiten Szenarios auf dem unbekanntem Streckenabschnitt getestet. Aufgrund der besten Generalisierungsfähigkeiten im ersten Szenario wird der 5 Uhr-Agent ausgewählt. Vom zweiten Szenario wird aufgrund der energieeffizienteren Fahrweise bei minimalen Einbußen der Pünktlichkeit der 7 Uhr-Agent gewählt. Um

die Fahrprofile der KI einordnen zu können, wird explizit für das dritte Szenario zur Verkehrszeit um 5 Uhr noch ein Deep-RL-Agent trainiert. Zudem werden Vergleiche mit den drei Fahrertypen aus dem regulären Fahrgastbetrieb vorgenommen.

Abbildung 6.23 zeigt drei Fahrprofile der Deep-RL-Agenten im dritten Szenario sowie die Geschwindigkeitsbeschränkungen der einzelnen Haltestellenabschnitte. Der explizit für dieses Szenario trainierte Agent ist in blau dargestellt. Der aus dem ersten Szenario ausgewählte Agent in orange, der Agent aus dem zweiten Szenario in grün. Die in den ersten beiden Szenarien trainierten Agenten weisen an zwei Stellen leichte Überschreitungen der Geschwindigkeitsbeschränkung auf. Zum einen in der Kurve in der Poststraße und zum anderen zwischen der Haltestelle Rüppurer Tor und der Haltestelle Werderstraße. Der Bremsvorgang der in anderen Szenarien trainierten Agenten funktioniert trotz der unterschiedlich langen Streckenabschnitte. Auffällig ist, dass das Fahrprofil des im ersten Szenario trainierten Agenten im ersten Streckenabschnitt näher an dem des explizit trainierten Agenten für das dritte Szenario liegt. Aufgrund der vergleichbaren Geschwindigkeitsbeschränkung im ersten Szenario ist der Szenario 1-Agent mit dieser Charakteristik bereits vertraut. [212]

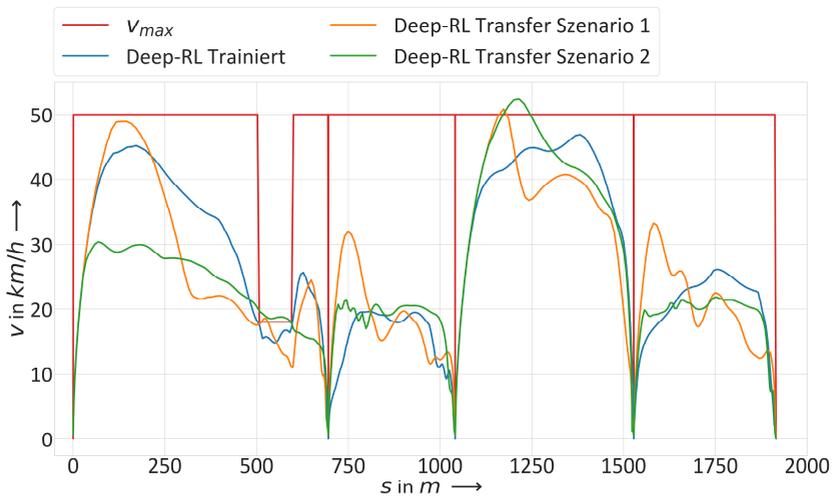


Abbildung 6.23: Fahrprofile der Deep-RL-Agenten im dritten Szenario zwischen der Haltestelle Durlacher Tor und dem Tivoli nach Tesar [212]

Tabelle 6.8 vergleicht die Fahrplanabweichung und den Energiebedarf des trainierten Agenten, der Agenten der Szenarien 1 und 2 sowie den drei Fahrertypen. Der speziell für das Szenario trainierte Agent zeigt die beste Fahrplanabweichung und wählt ein Fahrprofil mit der höchsten Energieeffizienz. Im Vergleich zu den drei Fahrertypen zeigen die beiden Agenten aus den weiteren Szenarien gute Fähigkeiten zum Wissenstransfer. Verglichen mit dem Agenten aus dem zweiten Szenario weisen keine Fahrer aus dem regulären Fahrgastbetrieb eine bessere Fahrplanabweichung und eine bessere Energieeffizienz auf. Die Pünktlichkeit des trainierten Agenten aus dem ersten Szenario übertrifft ebenfalls sämtliche Fahrertypen. Lediglich bei der Energieeffizienz haben der energieeffizienteste und der pünktlichste Fahrer leichte Vorteile. [212]

Dieses Ergebnis der KI fußt auf zwei Säulen. Zunächst ist der Anwendungsfall in der Karlsruher Innenstadt vergleichbar mit den ersten beiden Szenarien. Die Höchstgeschwindigkeiten liegen innerhalb des trainierten Versuchsraums

der ersten beiden Szenarien und es gibt ebenfalls keine Steigungen. Betrieblich haben die Haltestellenabschnitte sowohl ähnliche im Fahrplan vorgesehene Fahrzeiten als auch Haltedauern wie die Szenarien 1 und 2. Analog dazu verhält sich die Streckenlänge der Abschnitte. Des Weiteren konnte die KI durch den Beobachtungsraum aus Kapitel 5.4 sowie der Rewardfunktion aus Kapitel 5.5 grundlegende Zusammenhänge zwischen Fahrzeug, Betrieb und Infrastruktur erlernen. Dies macht sich im zweiten, dritten und vierten Haltestellenabschnitt bemerkbar. Abhängig von der im Fahrplan vorgesehenen Zeit für die Strecke bis zur nächsten Haltestelle wählt die KI eine angepasste Höchstgeschwindigkeit, was wiederum direkten Einfluss auf den Energiebedarf hat.

Tabelle 6.8: Fahrplanabweichungen und Energiebedarfe der verschiedenen Agenten und Fahrtypen im dritten Szenario nach Tesar [212]

	Fahrplanabweichung	Energiebedarf
Trainierter Agent	16 s	2,48 kWh
Szenario 1 Agent	35 s	2,85 kWh
Szenario 2 Agent	36 s	2,62 kWh
Durchschnittlicher Fahrer	69 s	3,00 kWh
Energieeffizientester Fahrer	63 s	2,83 kWh
Pünktlichster Fahrer	36 s	2,84 kWh

6.6 Diskussion und kritische Würdigung

Die Ergebnisse zeigen, dass mit einer trainierten KI die Energieeffizienz und die Pünktlichkeit auf zwei verschiedenen Szenarien gesteigert werden können. Durch die Gewichtung der Rewardfunktion aus Kapitel 5.5 priorisieren die Agenten eine minimale Fahrplanabweichung bei Einhaltung aller Geschwindigkeitsbeschränkungen. Nach der Umfeldanalyse in Kapitel 1.1 kann durch die Priorisierung der Pünktlichkeit die Anforderung der Endkunden nach einem hochverfügbaren und zuverlässigen System erfüllt werden.

Aufgrund der hohen Gewichtung der Pünktlichkeit in der Rewardfunktion weisen die Agenten noch Verbesserungspotential hinsichtlich der Energieeffizienz auf. In Haltestellenabschnitten, in denen kaum eine Fahrzeitreserve vorhanden ist, wird von den Agenten ein sehr geradliniges und optimiertes Fahrprofil gewählt. Sobald jedoch eine größere Fahrzeitreserve vorhanden ist, nutzen diese die Agenten nicht zwingend durch einen höheren Coasting-Anteil aus. Dies konnte durch die Klassifikation der Fahrweise aus Kapitel 4.3.3 nachgewiesen werden. Möglichkeiten, den Agenten ein solches Verhalten beizubringen, liegen in der Rewardfunktion. Die Herausforderung für die Agenten besteht in den vielen Möglichkeiten, welcher der kontinuierliche Aktionsraum des TD3-Algorithmus bietet. Die tatsächliche Belohnung auf Energieeffizienz und Pünktlichkeit wird erst beim Erreichen der Haltestelle vergeben. Bei der Pünktlichkeit sind die Auswirkungen des gewählten Fahrprofils schneller für den Agenten ersichtlich als bei einer energiesparenden Fahrweise. Möglich wäre, einen Reward ähnlich dem von r_2 aus Gleichung 5-3 zu nutzen. Dieser Reward könnte mit der verbleibenden Fahrzeit und dem Energiebedarf verknüpft werden. Eine weitere Möglichkeit wäre die Integration der Klassifikation in die Deep-RL-Umgebung und das Belohnen von Coasting.

Durch den Vergleich mit Dynamic Programming kann zusätzliches Verbesserungspotential des Energiebedarfs und der Pünktlichkeit aufgezeigt werden. Beherrschbare Rechenzeiten erfordern jedoch die Diskretisierung und Einschränkung des Aktionsraums. Daher handelt es sich um ein theoretisches Optimum unter den gegebenen Randbedingungen, jedoch nicht um das globale Optimum für das jeweilige Szenario. Der Wechsel von der höchsten Beschleunigung zur maximalen Verzögerung benötigt 10 Zeitschritte. Diese fahrdynamische Einschränkung hat Auswirkung auf die Pünktlichkeit. Durch die Diskretisierung des Aktionsraums kann Coasting nicht optimal eingesetzt werden, wodurch wiederum ein Potential bei der Energieeffizienz resultiert. Dennoch wäre der Versuch, das globale Optimum zu ermitteln, als wenig zielführend anzusehen. Dynamic Programming kann nicht als Alternative zu Deep Reinforcement Learning angesehen werden. Die möglichen Verbesserungen sind mit einer noch höheren Berechnungsdauer verbunden und können durch

die Optimierung auf ein bestimmtes Szenario nicht generalisieren. Daher eignet sich Dynamic Programming aufgrund der fehlenden Onlinefähigkeit bei der Berechnung von Fahrprofilen (vgl. Kapitel 3.2) nicht für eine Anwendung in einem Assistenzsystem.

Im zweiten Schritt werden die Agenten außerhalb ihrer trainierten Verkehrszeiten ohne weiteres Training getestet. Bislang beschränken sich Untersuchungen zum energieeffizienten und pünktlichen Betrieb von Schienenfahrzeugen auf die Optimierung vordefinierter Fahrzeiten und Haltedauern. Im täglichen Betrieb sind diese Zeiten jedoch variabel. An ein Assistenzsystem wird daher die Anforderung gestellt, dass dieses auch außerhalb der trainierten Bedingungen onlinefähig Fahrprofile berechnen kann.

In dieser Dissertation wird erstmals für das Bahnsystem nachgewiesen, dass Deep-RL-Agenten über Generalisierungsfähigkeiten zwischen Verkehrszeiten und Szenarien verfügen. Dabei übertreffen die Agenten auch außerhalb der trainierten Haltedauern Fahrer aus dem regulären Fahrgastbetrieb in der Energieeffizienz und der Pünktlichkeit. Abhängig von den Bedingungen, unter denen die Agenten trainiert werden, weisen diese bessere oder schlechtere Generalisierungsfähigkeiten auf. Für den Einsatz in einem Assistenzsystem sollten Agenten bevorzugt werden, die mit moderaten Haltedauern trainiert werden. Auf diese Weise erlernen die Agenten sowohl eine zeitminimale Fahrweise als auch eine angepasst energieeffiziente Fahrweise auf anderen Haltestellenabschnitten.

Dadurch, dass die trainierte KI unter abweichenden Haltedauern ebenfalls energieeffiziente und pünktliche Fahrprofile berechnet, sind die absoluten Werte der Haltedauern im initialen Training nicht essentiell für die spätere Anwendung. Für die in der Dissertation betrachteten Szenarien könnte gerade zu den Randzeiten am frühen Morgen und am späten Abend die Datengrundlage noch umfassender sein. Durch den erfolgreichen Nachweis der Generalisierung ist die Datengrundlage des Betriebs nicht essentiell für die spätere Anwendung. Zudem können Betriebsdaten auch über Betriebsleitsysteme bei den Verkehrsbetrieben erhoben werden.

In einem dritten Schritt wird sichergestellt, dass die KI nicht nur das spezifische Szenario erlernt, in welchem sie trainiert wird. In Abhängigkeit des vorliegenden Infrastruktur- und Betriebsmodells werden trainierte Deep-RL-Agenten ohne weiteres Training auf einem unbekanntem Szenario getestet. Die ermittelten Fahrprofile übertreffen erneut die Energieeffizienz und Pünktlichkeit der Fahrprofile der Fahrer aus dem Fahrgastbetrieb. Der Wissenstransfer auf neue Szenarien ist für den täglichen Betrieb jedoch weniger relevant als die Generalisierung zu unbekanntem Haltedauern. Falls es tatsächlich zu Anpassungen an der Linienführung kommt, wäre ein Training der KI für den neuen Streckenabschnitt vorteilhafter. Das Training eines Agenten für 3500 Episoden auf einer Strecke von ca. zwei Kilometern beläuft sich auf eine Rechenzeit von ungefähr vier Stunden.

Längere Strecken erfordern wiederum mehr Rechenleistung. Mit mehr Streckenabschnitten im Training ist jedoch denkbar, dass im Falle einer unplanmäßigen Umleitungsfahrt die Generalisierungsfähigkeiten verbessert werden könnten. Diese Hypothese ist durch den ersten Haltestellenabschnitt des dritten Szenarios begründet. In diesem Haltestellenabschnitt wählt der trainierte Agent aus Szenario 1 ein ähnliches Fahrprofil zum explizit für das Szenario trainierten Agenten aufgrund der vergleichbaren Streckenhöchstgeschwindigkeiten der Szenarien (vgl. Abbildung 6.3 und 6.9). Ob sich dieser Effekt über weitere Streckenabschnitte weiter manifestiert, muss untersucht werden.

Ein wesentlicher Eckpfeiler für die erfolgreiche Implementierung stellt das datengetriebene Energiebedarfsmodell dar. Im Vergleich zu bestehenden Modellen kann die Berechnungsdauer um den Faktor 230 reduziert werden, bei einer gleichzeitigen Erhöhung der Genauigkeit. Bei einer durchschnittlichen Berechnungszeit von 0,06 Sekunden pro Haltestellenintervall nach Tabelle 5.9 entfallen für die Energiebedarfsberechnung bei 3500 Episoden lediglich ca. 15 Minuten. Bei der Multi-Physik-Simulation würde allein die Berechnung des Energiebedarfs über 3500 Episoden mehr als 54 Stunden in Anspruch nehmen. Dies erschwert das Tuning der Rewards und das anschließende Training

der Agenten. Zudem müssten Schnittstellen zwischen Python und der Simulationsumgebung durch eine Co-Simulation hergestellt werden, was zusätzliche Rechenzeit benötigt.

Durch das valide Fahrzeugmodell (vgl. Anforderungen Kapitel 3.2) kann der Abgleich mit Fahrern aus dem regulären Fahrgastbetrieb durchgeführt werden. Mit dem entwickelten Umgebungsmodell ist ein Vergleich zwischen Fahrern und Deep-RL-Agenten möglich, der über die Modellierung bisheriger Forschungsarbeiten hinausgeht. Damit kann das tatsächliche Potential zur Steigerung von Energieeffizienz und Pünktlichkeit quantifiziert werden. Sämtliche Verbesserungen des Energiebedarfs gegenüber den durchschnittlichen Fahrern liegen in dieser Dissertation über dem Modellfehler des Energiebedarfsmodells.

Mit den Untersuchungen wird nachgewiesen, dass ein KI-basiertes Fahrerassistenzsystem mit Deep Reinforcement Learning in der Straßenbahn eingesetzt werden kann. Dieses Assistenzsystem hat das Potential, durch die vorgegebenen Fahrprofile die Energieeffizienz und Pünktlichkeit im Vergleich zu Fahrern zu verbessern. Die vom Assistenzsystem vorgeschlagenen Geschwindigkeitstrajektorien können aufgrund des kontinuierlichen Aktionsraums durch die Anwendung des TD3-Algorithmus durch die Fahrer umgesetzt werden. Physikalisch wird durch die Limitierung des Aktionsraums der maximalen Beschleunigung und Verzögerung sichergestellt, dass die Grenzen der Fahrdynamik eingehalten werden. In den trainierten Szenarien sind ebenfalls keine Verstöße gegen die Höchstgeschwindigkeiten festzustellen. Der Fahrer hat die Möglichkeit, das System jederzeit zu überstimmen, wodurch keine Hürden in der Zulassung entstehen. Des Weiteren kann das System in der Fahrschule eingesetzt werden, um neue Fahrer beim Erlernen einer energie-sparenden und pünktlichen Fahrweise zu unterstützen.

Die Berechnungsdauer von Fahrprofilen durch trainierte Agenten auf einzelnen Haltestellenabschnitten ist geringer als eine Sekunde und erfüllt damit die geforderte Onlinefähigkeit (vgl. Kapitel 3.2). Sollten die Haltedauern vom

durchschnittlich trainierten Szenario abweichen, kann kurzerhand ein angepasstes Fahrprofil ermittelt werden. Damit kann bei einem Einsatz als Assistenzsystem weiterhin eine energieeffiziente und pünktliche Fahrweise aufgrund der Generalisierungsfähigkeiten der KI garantiert werden.

Mit einer zusätzlichen Geschwindigkeitsüberwachung und der Implementierung von Bremskurven angelehnt an ETCS [63] wäre ein GoA 2-Betrieb mit dem System möglich.

7 Zusammenfassung und Ausblick

7.1 Zusammenfassung

Energieeffizienz und Pünktlichkeit stehen im Bahnsystem in einem Zielkonflikt. Fahrprofile zur Lösung dieser konkurrierenden Zielstellungen werden bereits mit konventionellen Methoden optimiert. Damit konnten in einzelnen Szenarien zu spezifischen Fahr- und Verkehrszeiten Geschwindigkeitstrajektorien ermittelt werden, welche den Energiebedarf bei einer pünktlichen Fahrweise minimieren. Sobald die betrieblichen Parameter nicht mehr mit dem ursprünglichen Szenario übereinstimmen, ist das gewählte Fahrprofil jedoch nicht mehr optimal. Speziell im Bereich der Straßenbahnen gestalten sich Fahrzeiten und Haltedauern variabel über den täglichen Betrieb und die Automatisierungsmöglichkeiten sind begrenzt.

In dieser Dissertation wurde daher untersucht, wie die Energieeffizienz und Pünktlichkeit von Straßenbahnen durch den Einsatz von Deep Reinforcement Learning gesteigert werden kann. Zudem war Gegenstand der Forschung, wie trainierte Agenten ihr erlerntes Wissen auf unbekanntem Haltedauern und unbekanntem Strecken ohne weiteres Training generalisieren.

Für diese Untersuchungen wurde ein gesamtes Deep Reinforcement Learning-System aufgebaut. Dieses wurde durch Messdaten aus dem regulären Fahrgastbetrieb parametrisiert und validiert. Dadurch wurde eine Vergleichbarkeit zwischen den Fahrprofilen der trainierten KI und den Fahrern aus dem Fahrgastbetrieb sichergestellt.

Bezugnehmend auf die Forschungshypothesen aus Kapitel 3.3 werden die zentralen Erkenntnisse der Dissertation zusammengefasst.

Forschungshypothese 1 – Mit dem Einsatz von Deep-RL-Agenten kann die Energieeffizienz und Pünktlichkeit gesteigert werden.

Auf zwei verschiedenen Szenarien zu jeweils drei Verkehrszeiten wurden Deep-RL-Agenten trainiert. Die trainierten Agenten wurden mit den durchschnittlichen Fahrern, den energieeffizientesten Fahrern und den pünktlichsten Fahrern für jede Verkehrszeit verglichen.

Gemittelt über beide Szenarien kann die KI gegenüber den durchschnittlichen Fahrern die Fahrplanabweichung um 65 Sekunden und den Energiebedarf um 0,37 kWh (-11,1 %) reduzieren. Gegenüber den energieeffizientesten Fahrern wird die Fahrplanabweichung um 73 Sekunden gesenkt. Der Energiebedarf erhöht sich um 0,11 kWh (+3,35 %). Im Vergleich zu den pünktlichsten Fahrern wird die Fahrplanabweichung um 23 Sekunden und der Energiebedarf um 0,07 kWh (-2,4 %) reduziert.

Als weiterer Vergleich wurde ein durch Dynamic Programming ermitteltes theoretisches Optimum hinzugezogen. Dieses kann in beiden Szenarien die Fahrplanabweichung um durchschnittlich 10 Sekunden gegenüber den trainierten Agenten reduzieren. Der Energiebedarf reduziert sich durch die Fahrprofile um weitere 0,14 kWh (-4,3 %). Dynamic Programming verfügt jedoch als konventionelles Verfahren über keine Generalisierungsfähigkeiten.

Forschungshypothese 2 – Innerhalb eines Szenarios können Deep-RL-Agenten einen Wissenstransfer erbringen.

Zur Untersuchung der Generalisierungsfähigkeiten wurden die trainierten Agenten der jeweiligen Verkehrszeiten auf allen weiteren Haltedauern von 5 bis 23 Uhr ohne weiteres Training getestet. Der Transfer auf neue Haltedauern war bei allen Agenten erfolgreich. Damit wird die grundsätzliche Eignung von Deep Reinforcement Learning zur Berechnung von Fahrprofilen für Assistenzsysteme nachgewiesen. Diese Herausforderung wurde erstmals im Bahnsystem durch den Einsatz intelligenter Systeme gelöst.

Auf den beiden Szenarien über den gesamten Tag kann der am besten generalisierende Agent im Mittel die Fahrplanabweichung gegenüber den durchschnittlichen Fahrern um 76 Sekunden und den Energiebedarf um 0,58 kWh (-19 %) reduzieren. Die Verringerung der Fahrplanabweichung im Vergleich zu den energieeffizientesten Fahrern beträgt 85 Sekunden bei einer gleichzeitigen Senkung des Energiebedarfs um 0,03 kWh (-1 %). Verglichen mit den pünktlichsten Fahrern kann im Schnitt die Fahrplanabweichung um 30 Sekunden und der Energiebedarf um 0,41 kWh (-13,7 %) reduziert werden.

Forschungshypothese 3 – Deep-RL-Agenten können das erlernte Wissen auf einen neuen Anwendungsfall transferieren.

Zur Untersuchung des Wissenstransfers auf neue Strecken wurde eine Umleitungsfahrt ohne weiteres Training simuliert. Damit wurde sichergestellt, dass die Agenten abhängig von der vorliegenden Infrastruktur und den Haltedauern die Fahrprofile anpassen. Diese Transferleistung konnte in dieser Dissertation ebenfalls durch den Einsatz von Deep Reinforcement Learning erstmals nachgewiesen werden.

Beide Agenten der Szenarien 1 und 2 zeigen erneut Generalisierungsfähigkeiten und übertreffen die Pünktlichkeit und die Energieeffizienz der durchschnittlichen Fahrer auf dem unbekanntem Streckenabschnitt, welcher ebenfalls durch die Karlsruher Innenstadt verläuft.

Forschungshypothese 4 – Der KI-Trainingsprozess kann durch den Einsatz datengetriebener Modellierungsverfahren verbessert werden.

Ein wesentlicher Bestandteil der Deep-RL-Umgebung stellt das DIN 50591-konforme datengetriebene Energiebedarfsmodell für das Traktionssystem dar. Verglichen mit bestehenden Simulationsmodellen am Institut konnte die Rechenzeit um den Faktor 230 verringert werden. Bei einem vollständigen Trainingsdurchlauf eines Deep-RL-Agenten entfallen auf die Energiebedarfsberechnung lediglich ca. 30 Minuten. Das Multi-Physik-Simulationsmodell

würde allein für die Berechnung des Energiebedarfs bei 3500 Trainingsepisoden mehr als 54 Stunden benötigen. Dadurch werden mit dem datengetriebenen Energiebedarfsmodell ein effizienteres Tuning der Rewards und ein beschleunigtes Training bei gleichzeitig erhöhter Genauigkeit ermöglicht.

7.2 Ausblick

In dieser Dissertation wurden in einem aufgebauten Deep Reinforcement Learning-System verschiedene Agenten trainiert, die energieeffiziente und pünktliche Fahrtrajektorien ermitteln. Diese Agenten haben Fähigkeiten zur Generalisierung der Fahrprofile auf abweichende Haltedauern und neue Streckenabschnitte gezeigt.

Umsetzung als Assistenzsystem im Fahrzeug

Die KI hat in der Softwareumgebung nachgewiesen, dass die ermittelten Fahrprofile die Energieeffizienz und die Pünktlichkeit verbessern. Im nächsten Schritt gilt es, das System auf einem Fahrzeug zu implementieren und die Fahrer damit in ihrer täglichen Aufgabe zu unterstützen. Dadurch kann das Verbesserungspotential im regulären Betrieb über einen längeren Zeitraum quantifiziert werden. Ebenfalls kann das System in Fahrschulfahrzeugen eingesetzt werden, um angehende Fahrer beim Erlernen energieeffizienter und pünktlicher Fahrtrajektorien zu unterstützen. Geeignete Strecken zur Überprüfung der Funktionalität wären Streckenabschnitte wie im zweiten Szenario oder auf den Linien S1 und S11 im Schwarzwald ohne Interaktionen mit dem Individualverkehr.

Um eine erfolgreiche Implementierung des Systems zu gewährleisten, muss das Fahrpersonal einbezogen werden. Die Fahrempfehlung für die Fahrer kann visuell, per Audio oder kombiniert erfolgen. In Workshops und Vorstudien kann eine optimale Mensch-Maschine-Schnittstelle entworfen werden, damit die Fahrer die Vorgaben des Assistenzsystems bestmöglich umsetzen.

Mit einer kontinuierlichen Datenerfassung während des Betriebs kann zudem überprüft werden, ob es über die Zeit aufgrund möglicher externer Einflüsse zu abweichenden Haltedauern kommt. Insofern sich dies bestätigt, kann bei einer Abweichung der Haltedauern ab einem zu definierenden Schwellwert der Agent neu trainiert werden.

Integration der Funktionen in ein Backend und Skalierung des Assistenzsystems auf die Flotte

Das Umgebungsmodell aus Fahrzeug, Betrieb und Infrastruktur könnte zentral in einem Backend hinterlegt und allen Fahrzeugen der Flotte zur Verfügung gestellt werden. In Abhängigkeit der gefahrenen Route könnte den Fahrzeugen an jeder Haltestelle eine energieeffiziente und pünktliche Fahrtrajektorie für den nächsten Haltestellenabschnitt angepasst an die betriebliche Situation übermittelt werden.

Bislang könnten alle Fahrzeuge der NET 2012-Flotte mit einem solchen Assistenzsystem ausgerüstet werden. Die Verkehrsbetriebe Karlsruhe betreiben noch weitere Fahrzeugtypen, für welche durch die Aufzeichnung von Fahrzeugdaten ebenfalls valide Energiebedarfsmodelle generiert werden können. Mit dem daraus erstellten Fahrzeugmodell wäre es wiederum möglich, Deep-RL-Agenten zur energieeffizienten und pünktlichen Fahrweise zu trainieren. Da die Einsparungen im Energiebedarf nicht an das einzelne Fahrzeug gekoppelt sind, sondern aus der Optimierung des Fahrprofils stammen, könnte bei einem flottenweiten Einsatz über alle Fahrzeuge der gesamte Traktionsenergiebedarf von ungefähr jeder zehnten Bahn eingespart werden.

Übertrag auf Heizungs-, Klimatisierungs- und Lüftungssteuerung sowie weitere Verkehrsträger

Nebenverbraucher sind je nach Linie und Wetter für bis zu 50 % des Energiebedarfs bei Straßenbahnen verantwortlich [209]. Das methodische Vorgehen kann identisch für die Steuerung der Heizung, Klimatisierung und Lüftung von

Straßenbahnen umgesetzt werden. Nach dem Aufbau und der Parametrierung des Umgebungsmodells können Agenten trainiert werden, die die Steuerung der Nebenverbraucher optimieren und damit den Energiebedarf reduzieren.

Des Weiteren ist denkbar, die Fahrprofile auch auf vergleichbare Verkehrsträger auszurollen. Elektrobusse haben zur Straßenbahn verwandte Betriebskonzepte und unterliegen durch die Fahrgastströme sowie dem Individualverkehr ähnlichen Herausforderungen. Mit der Ausrüstung eines Messfahrzeugs im regulären Fahrgastbetrieb kann ebenfalls die methodische Vorgehensweise umgesetzt werden. Damit können Untersuchungen zur Steigerung von Energieeffizienz und Pünktlichkeit untersucht werden.

Training vollständiger Linien

Bislang wurden die Agenten nur auf einzelnen Streckenabschnitten trainiert. Damit das System in der Praxis vollumfänglich eingesetzt werden kann, müssen jedoch ganze Linien trainiert werden. Hierfür wäre eine noch performantere Rechnerinfrastruktur notwendig. Durch mehr trainierte Haltestellenabschnitte könnten die Generalisierungsfähigkeiten weiter verbessert und untersucht werden.

Vernetzung und Multi-Agenten-System

Bisher wurde nur ein Fahrzeug für die Analysen betrachtet. Durch eine erhöhte Vernetzung mit anderen Verkehrsteilnehmern und der Infrastruktur sind zusätzliche Effizienz- und Pünktlichkeitssteigerungen zu erwarten. In der aufgebauten Umgebung können Lichtsignalanlagen sowie weitere Fahrzeuge implementiert werden, wodurch mittels Kommunikation zwischen diesen Teilnehmern das Fahrprofil angepasst werden kann. Damit können die Effekte einer erhöhten Vernetzung untersucht werden.

Hierfür ist die Ausrüstung der Lichtsignalanlagen und weiterer Fahrzeuge mit Kommunikationstechnik nötig, damit das Umgebungsmodell weiterhin mit validen Daten parametrisiert werden kann.

A Anhang

A.1 Stand der Technik und Wissenschaft zur Automatisierung im öffentlichen Verkehr

Der öffentliche Verkehrssektor bietet sehr gute Voraussetzungen für eine Automatisierung. Fahrzeuge fahren nach einem vordefinierten Fahrplan auf geplanten Routen und stoppen an ausgewählten Haltestellen. Diese Regelmäßigkeit der Betriebsabläufe unterscheidet den öffentlichen Verkehr vom Güterverkehr und steigert das Automatisierungspotential. Die Fahrzeugflotte im öffentlichen Verkehr ist kontinuierlich auf den vordefinierten Routen im Einsatz. Durch diese Datengrundlage lassen sich bestehende Systeme weiter optimieren und langfristig auch die Fahraufgabe automatisieren [175]. Das Bestreben, den öffentlichen Verkehr zu automatisieren, ist mit den Möglichkeiten verbunden, Energie einzusparen, eine erhöhte Verfügbarkeit und Pünktlichkeit der Fahrzeuge zu gewährleisten sowie die Personalkosten zu reduzieren. Personalkosten belaufen sich bei Verkehrsunternehmen zum Teil auf mehr als 50 % des jährlichen Aufwands. [177, 178]

In Bahnsystemen mit separatem Gleiskörper werden seit Jahrzehnten infrastrukturseitige Zugsicherungssysteme verwendet. Die systemimmanente Spurführung erhöht das Automatisierungspotential. Auf den Hauptstrecken des deutschen Schienennetzes wird seit mehr als 50 Jahren die Linienförmige Zugbeeinflussung (LZB) eingesetzt [110]. Ende 2021 sind in Deutschland 2.609 der 33.288 Kilometer des Netzes der Deutschen Bahn mit LZB ausgerüstet [44]. Die Übertragung der Daten erfolgt durch einen Linienleiter zwischen den Schienen. Dieser Linienleiter ist mit einem Rechenzentrum verbunden, von wo aus die Streckenführung überwacht wird. In Kombination mit einer automatischen Fahr- und Bremssteuerung sowie weiteren Assistenzsystemen wie dem elektronischen Buchfahrplan [45] oder dem Ecotrainbook [121] kann durch die LZB der Fahrer in einer energiesparenden Fahrweise unterstützt

werden. Nach den Automatisierungsgraden (vgl. Kapitel 1.2.1) entspricht dies einem Betrieb mit GoA 1. [110]

Mit einem Zugbeeinflussungssystem wie der LZB können in abgeschlossenen Systemen wie Metros oder U-Bahnen noch höhere Automatisierungsgrade erreicht werden. Die U-Bahn in Nürnberg ist mit einer LZB ausgerüstet und seit 2008 im vollautomatischen Betrieb (GoA 4) im Einsatz. [202] In Metro-Systemen wird diese Automatisierung heutzutage nicht mehr durch eine LZB umgesetzt, sondern durch den Einsatz von CBTC [106]. Mittlerweile werden in 42 Städten 64 vollautomatische U-Bahn-Linien mit insgesamt mehr als 1000 Streckenkilometern betrieben [220]. Für neue Metro-Systeme ist der vollautomatische fahrerlose Zugbetrieb Stand der Technik [242].

Im Vollbahnbereich läuft die Automatisierung langsamer voran. Durch ausgedehnte Streckennetze, einer inhomogenen Fahrzeugflotte und dem Mischbetrieb von Güter- und Personenverkehr wird der Automatisierungsprozess gehemmt. Zudem bedarf es bei der Automatisierung der Zusammenarbeit von Verkehrsunternehmen und Infrastrukturbetreiber, um sowohl fahrzeug- als auch infrastrukturseitig die notwendige Technologie auszurüsten. [202] Zukünftig wird für den Vollbahnbereich ein halbautomatischer Zugbetrieb (GoA 2) durch den Einsatz des Zugbeeinflussungssystems ETCS in Kombination mit digitalen Stellwerken angestrebt [54, 61, 247]. Darüber hinaus gibt es Untersuchungen zur Integration zusätzlicher Sensorik, um Fahrer bei der Abfertigung an Bahnhöfen zu unterstützen sowie eigenständig Gefahren im Gleis zu erkennen und gegebenenfalls einen Bremsvorgang einzuleiten [122, 191, 216].

Abgeschlossene Bahnsysteme oder Systeme mit separatem Gleiskörper nehmen eine Sonderrolle bei der Automatisierung des öffentlichen Verkehrs ein. Der Großteil der Personenkilometer im öffentlichen Verkehr wird durch Busse und Straßenbahnen erbracht [233]. Sowohl Busse als auch Straßenbahnen sind während des täglichen Betriebs Interaktionen mit weiteren Teilnehmern des Individualverkehrs ausgesetzt, da diese nicht in einem abgeschlossenen System oder dauerhaft auf separaten Verkehrswegen betrieben werden.

Diese Interaktionen erschweren die Automatisierung, da Systeme lernen müssen, mit diesen Einflüssen umzugehen. Tests von automatisierten Fahrfunktionen in dieser Umgebung sind herausfordernd und nicht flächendeckend umsetzbar. [177, 178]

Eine Möglichkeit, automatisierte Fahrfunktionen zu evaluieren, ist die Entwicklung und der Test von Automatisierungslösungen für die Betriebshöfe von Straßenbahn- und Busbetreibern [23]. Betriebshöfe sind meist nicht für die Öffentlichkeit zugänglich und auf dem Gelände ist geschultes Personal im Einsatz [178]. Insofern Lösungen auf dem Betriebshof entwickelt werden, haben diese die Anforderung einer Generalisierbarkeit [22, 177]. Sämtliche Szenarien, in welchen Funktionen auf dem Betriebshof erlernt und getestet werden, müssen den Regeln des späteren Einsatzgebiets folgen. Dazu zählen Schilder, Signalisierungen sowie die jeweilige Verkehrs- und Betriebsordnung. [125] Des Weiteren wird die Anforderung einer kontinuierlichen Transformation gestellt [22, 177]. Neue Funktionen sollen kontinuierlich im Einklang mit bisherigen Systemen entwickelt werden. [22, 177]

Auf dem Betriebshof kann eine Einsatzfähigkeit der automatisierten Fahrzeuge im Mischverkehr mit nicht automatisierten Verkehrsteilnehmern untersucht werden [8]. Zusätzliche Potentiale der Automatisierung liegen in der Kommunikation von Fahrzeugen mit der Infrastruktur und weiteren Verkehrsteilnehmern (Vehicle2X,V2X) [147]. Die dadurch gewonnenen Informationen können ebenfalls zur Optimierung der Fahraufgabe und zu einer erhöhten Sicherheit beitragen. [9]

Fahrzeuge müssen zudem im täglichen Betrieb in der Lage sein, Hindernisse zu detektieren und mögliche Kollisionen zu vermeiden [100]. Dazu bietet sich der Betriebshof an, um Verfahren des maschinellen Sehens [76] und der Umfeldperzeption [133] zu erproben. Des Weiteren kann auf ausgewählten Abschnitten im Betriebshof die Erprobung von Algorithmen und Optimierungen zur Automatisierung der Fahraufgabe durchgeführt werden [140, 162].

Zusätzlich können Konzepte zum Platooning von Bussen [114, 201] und Stra-

ßenbahnen [249] untersucht werden. In Bereichen mit hoher Nachfrage können mehrere Fahrzeuge elektronisch gekoppelt und anschließend wieder geflügelt werden [114].

Neben der Automatisierung konventioneller Straßenbahnen und Bussen wird ebenfalls der Einsatz von automatisierten Kleinbussen in Testfeldern erprobt. Die Automatisierung ist mit den gleichen Herausforderungen verbunden, die vollständige Substitution des Fahrers erschwert die Zulassung jedoch ungem. [26, 102, 188]

A.2 Einfluss der Hyperparameter auf die Energiebedarfsprädiktion des Fahrzeugmodells

Abbildung A.1 (a) zeigt die bekannten Zusammenhänge zwischen der Abtastfrequenz und dem MAPE für die verschiedenen Arten der Neuronalen Netze und dem Modellierungsinput auf.

Abbildung A.1 (b) zeigt den Zusammenhang zwischen der Anzahl der Schichten der Neuronalen Netze und dem MAPE. Aufgetragen auf der x-Achse ist die Gesamtzahl an Schichten der Neuronalen Netze. CNN und LSTM haben mindestens eine vollvernetzte und eine für das jeweilige Netz charakteristische Schicht. Dadurch verfügen diese in Summe über mindestens zwei Schichten. Ebenso gibt es im mesoskopischen Fall mindestens zwei Schichten aufgrund des Aufbaus nach Abbildung 5.3. Für den MAPE zeigt sich, dass die Energiebedarfsprädiktion bereits mit wenigen Schichten funktioniert. Zu viele Schichten verursachen ein Overfitting und führen zu schlechteren Ergebnissen.

In Abbildung A.1 (c) ist der Zusammenhang zwischen der Anzahl der Neuronen je Schicht und dem MAPE für mikroskopische Modelle dargestellt. Dabei ist festzustellen, dass die Prädiktion des Energiebedarfs mit einer geringen

Anzahl an Neuronen in einem höheren Fehler als bei einer hohen Anzahl Neuronen resultiert.

Die Abbildung A.1 (d) visualisiert den Zusammenhang zwischen der Anzahl der Neuronen und dem MAPE für die mesoskopische Modellierung. In diesem Fall zeigt sich, dass kein nennenswerter Einfluss der Anzahl der Neuronen je Schicht auf die Energiebedarfsprädiktion feststellbar ist.

Der Einfluss der Anzahl der Histogramm-Klassen auf die Energiebedarfsprädiktion der mesoskopischen Modelle ist wiederum deutlich in Abbildung A.1 (e) zu sehen. Auf der x-Achse aufgetragen sind die verschiedenen Klassenkonfigurationen. K1 steht für die Auflösung (5,5,6,4), K2 für (10,10,11,4), K3 für (20,20,22,4) und K4 für (30,30,33,4) nach Tabelle 5.5. Durch die zu geringe Auflösung von K1 und die zu feine Auflösung von K4 verschlechtert sich der durchschnittliche MAPE. Die Prädiktion des Energiebedarfs erzielt für K2 und K3 die besten Ergebnisse. Für MLP ist K2 die beste Konfiguration, während für CNN sowohl mit K2 als auch mit K3 der Energiebedarf mit dem geringsten Fehler geschätzt wird.

Abschließend ist in Abbildung A.1 (f) der Einfluss der Droprate auf den MAPE dargestellt. Durch die Droprate soll einem potentiellen Overfitting entgegen gewirkt werden, indem ein definierter Prozentsatz an Neuronen in den vollvernetzten Schichten zufällig ausgeschaltet wird. Da das Overfitting nach Abbildung 5.6 (c) nicht durch eine erhöhte Anzahl an Neuronen bedingt ist, führt auch eine erhöhte Droprate zu keinen Verbesserungen bei der Prädiktion des Energiebedarfs. Dropout hat sich in großen Neuronalen Netzen als Regularisierungstechnik bewährt. Möglich ist, dass die hier verwendeten Neuronalen Netze noch zu klein sind, dass durch die Droprate eine Verbesserung auftritt.

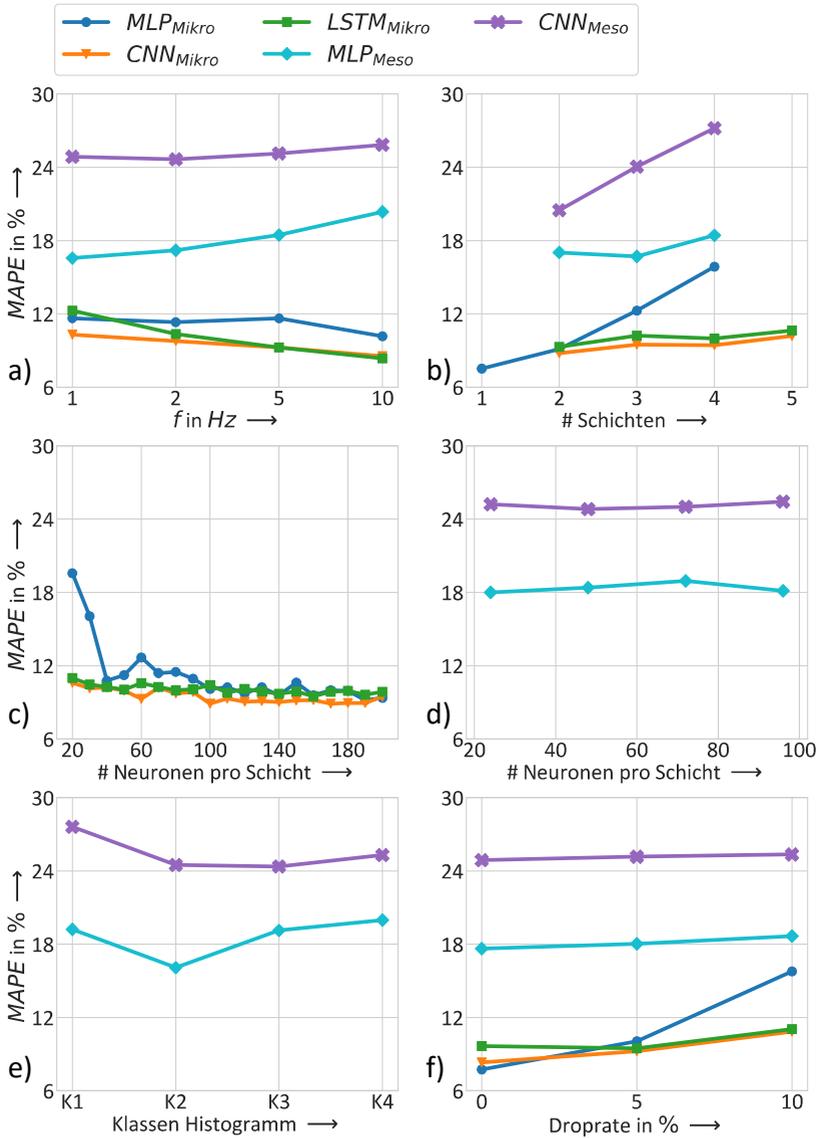
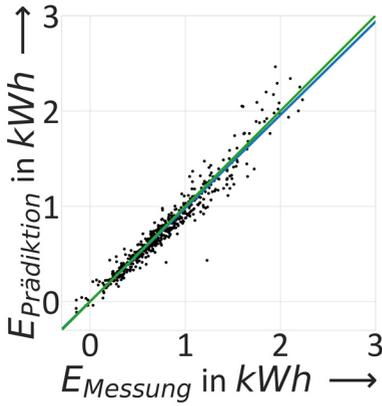
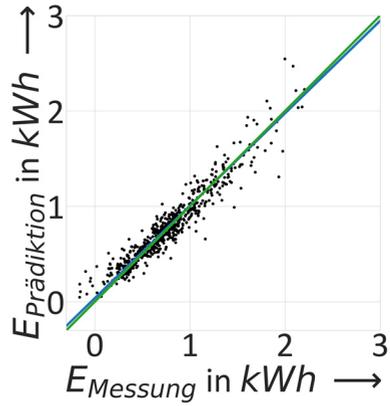


Abbildung A.1: Einfluss der Designparameter auf die Prädiktion des Energiebedarfs

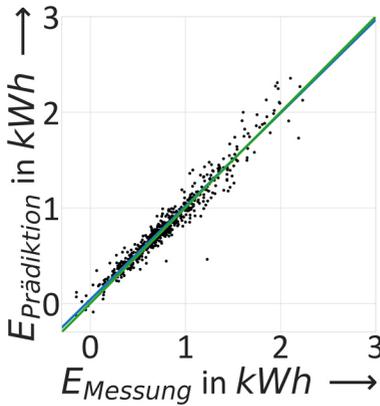
A.3 Energiebedarfsprädiktion der Modelle auf dem Evaluationsdatensatz



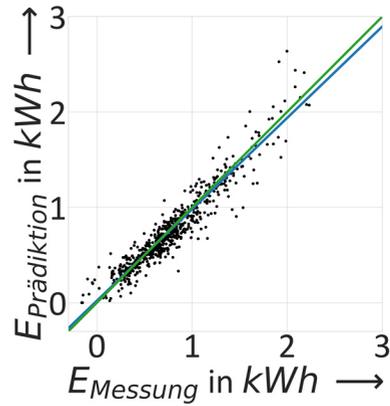
(a) 2 Hz MLP mikroskopisch



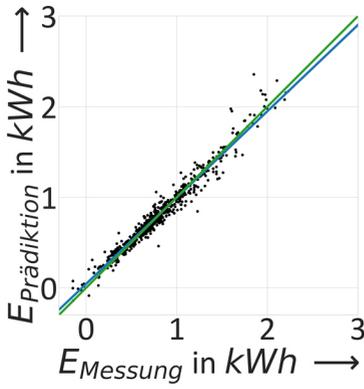
(b) 2 Hz MLP mesoskopisch



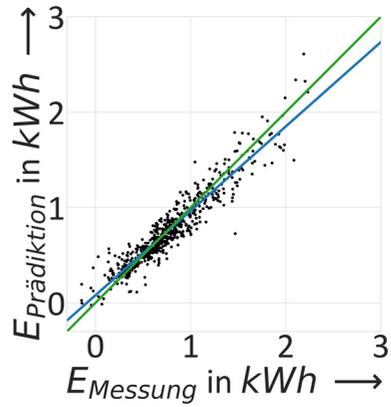
(c) 5 Hz MLP mikroskopisch



(d) 5 Hz MLP mesoskopisch

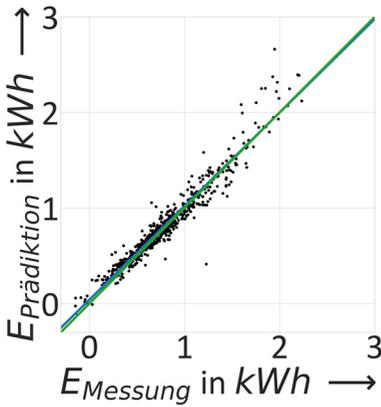


(e) 10 Hz MLP mikroskopisch

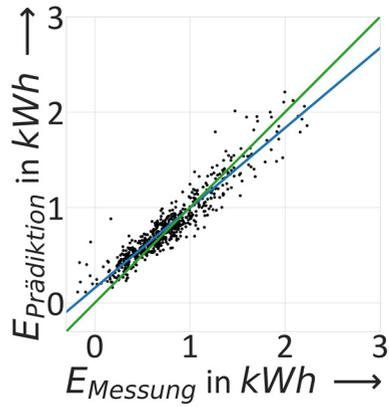


(f) 10 Hz MLP mesoskopisch

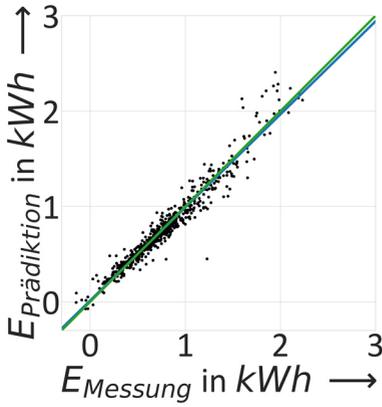
Abbildung A.2: Vergleich mikroskopische und mesoskopische MLP



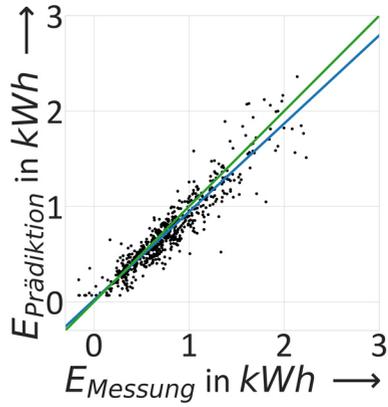
(a) 1 Hz CNN mikroskopisch



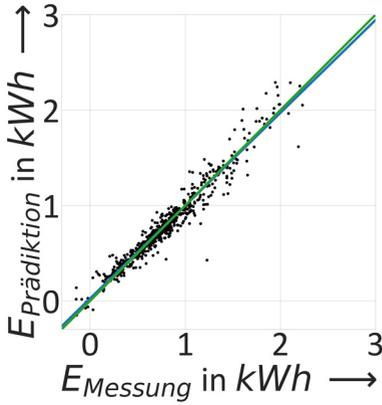
(b) 1 Hz CNN mesoskopisch



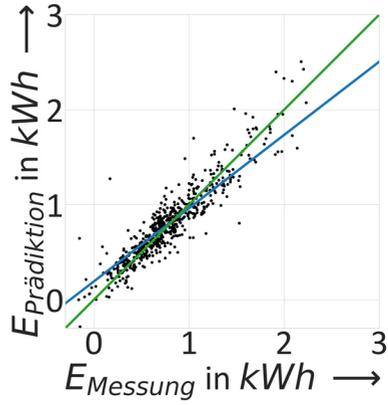
(c) 2 Hz CNN mikroskopisch



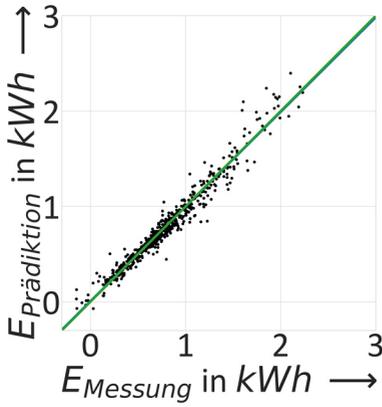
(d) 2 Hz CNN mesoskopisch



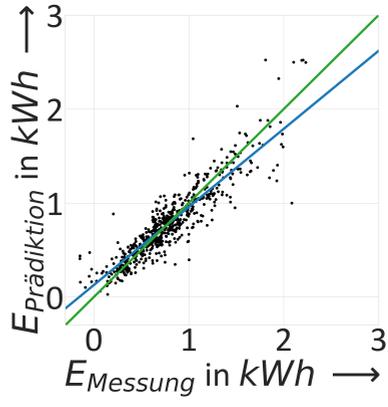
(e) 5 Hz CNN mikroskopisch



(f) 5 Hz CNN mesoskopisch

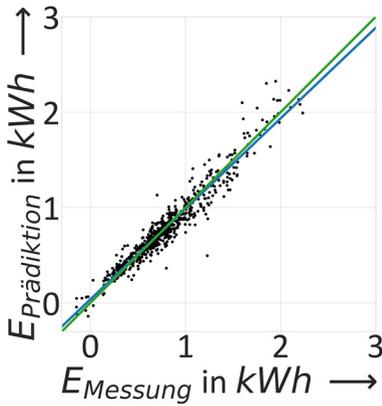


(g) 10 Hz CNN mikroskopisch

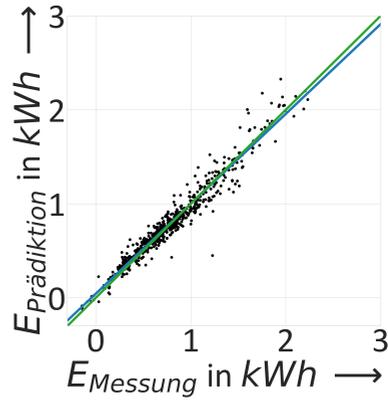


(h) 10 Hz CNN mesoskopisch

Abbildung A.3: Vergleich mikroskopische und mesoskopische CNN



(a) 1 Hz LSTM mikroskopisch



(b) 2 Hz LSTM mikroskopisch

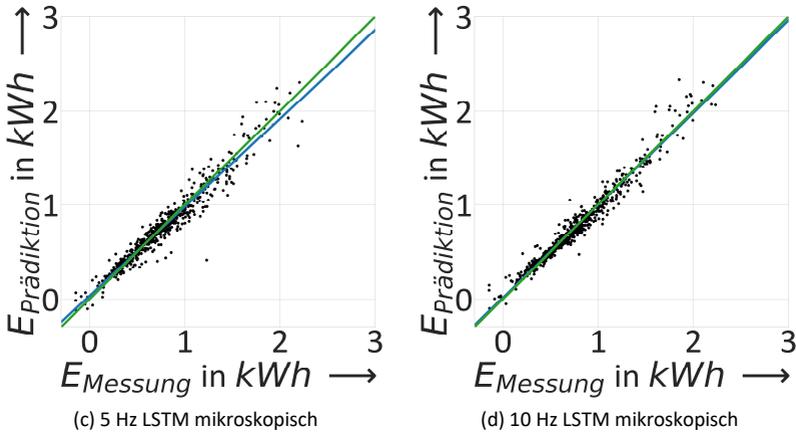


Abbildung A.4: Vergleich mikroskopische LSTM

A.4 Veränderte Rewardfunktion

Gleichung A-1 und A-2 zeigen die veränderten Rewards für die Pünktlichkeit und die Energieeffizienz. Eine unpünktliche Ankunft an der Haltestelle wird nur noch ein Drittel so stark gewichtet. Der Energiebedarf wird jedoch dreifach so stark gewichtet wie in den ursprünglichen Rewards.

$$r_5 = -200 \cdot |t_{\text{Fahrzeit}} - t_{\text{Fahrplan}}|, s = s_{\text{Halt}} \quad (\text{A-1})$$

$$r_6 = -24000 \cdot E_{\text{Abschnitt}}, s = s_{\text{Halt}} \quad (\text{A-2})$$

Tabelle A.1: Energiebedarf und Fahrplanabweichung der trainierten Agenten des ersten Szenarios mit veränderter Rewardfunktion

	Energiebedarf	Fahrplanabweichung
Szenario 1: 5 Uhr	2,42 kWh	33 s
Szenario 1: 7 Uhr	2,52 kWh	85 s
Szenario 1: 11 Uhr	2,48 kWh	38 s

Tabelle A.2: Energiebedarf und Fahrplanabweichung der trainierten Agenten des zweiten Szenarios mit veränderter Rewardfunktion

	Energiebedarf	Fahrplanabweichung
Szenario 2: 5 Uhr	2,89 kWh	50 s
Szenario 2: 7 Uhr	2,95 kWh	47 s
Szenario 2: 11 Uhr	2,92 kWh	60 s

In beiden Szenarien zeigen die trainierten Agenten mit der neuen Rewardfunktion das beabsichtigte Verhalten. Während des Trainings wird eine energiesparende Fahrweise gelernt. Dadurch wird der durchschnittliche Energiebedarf im Gegensatz zu den drei ursprünglich trainierten Agenten im ersten Szenario um 11,7 % reduziert. Dies geht jedoch mit einer Erhöhung der Fahrplanabweichung um 23 Sekunden einher.

Im zweiten Szenario kann der Energiebedarf durch die neue Rewardfunktion um 13,7 % gesenkt werden. Auch hier geht der reduzierte Energiebedarf mit einer Erhöhung der Fahrplanabweichung einher. Diese beträgt im zweiten Szenario 32 Sekunden.

Je nach Anwendungsfall und Zielsetzung kann die Rewardfunktion hinsichtlich des gewünschten Verhaltens angepasst werden. Aufgrund der Fokussierung auf ein hochverfügbares und möglichst pünktliches System stellt die Optimierung auf eine minimale Fahrplanabweichung den Endkundennutzen in den Vordergrund.

A.5 Auswertung unbekannter Haltedauern

Tabelle A.3: Fahrplanabweichung und Energiebedarf der verschiedenen Fahrertypen zu allen Haltedauern des ersten Szenarios

	Fahrplanabweichung [s]			Energiebedarf [kWh]		
	DF	EF	PF	DF	EF	PF
5 Uhr	68	63	18	3,08	2,77	2,98
6 Uhr	100	154	49	3,06	2,61	3,53
7 Uhr	155	178	39	3,16	2,89	3,03
8 Uhr	120	172	38	3,38	2,67	3,13
9 Uhr	89	174	47	3,20	2,73	2,79
10 Uhr	98	60	12	3,26	2,84	3,45
11 Uhr	95	86	40	3,30	2,84	2,99
12 Uhr	93	70	38	3,30	2,69	3,44
13 Uhr	121	91	58	3,43	2,57	3,22
14 Uhr	88	146	34	3,31	2,53	3,20
15 Uhr	93	152	44	3,26	2,93	3,20
16 Uhr	108	48	27	3,43	2,94	3,60
17 Uhr	97	36	36	3,31	2,75	2,75
18 Uhr	92	113	59	3,34	2,86	3,26
19 Uhr	88	37	37	3,12	2,62	2,62
20 Uhr	79	56	38	3,23	2,82	3,12
21 Uhr	93	81	36	3,18	2,62	3,22
22 Uhr	67	80	36	3,21	3,02	3,31
23 Uhr	59	72	36	3,13	2,76	3,30

Tabelle A.4: Fahrplanabweichung und Energiebedarf der Deep-RL-Agenten zu allen Haltedauern des ersten Szenarios

	Fahrplanabweichung [s]			Energiebedarf [kWh]		
	KI 5 Uhr	KI 7 Uhr	KI 11 Uhr	KI 5 Uhr	KI 7 Uhr	KI 11 Uhr
5 Uhr	17	57	21	2,64	3,18	2,68
6 Uhr	23	29	26	2,78	3,04	2,76
7 Uhr	76	52	78	2,66	2,96	2,71
8 Uhr	31	30	39	2,70	3,13	2,86
9 Uhr	27	41	30	2,70	2,87	2,71
10 Uhr	31	36	34	2,74	3,06	2,75
11 Uhr	21	33	19	2,67	3,23	2,69
12 Uhr	24	29	27	2,75	3,12	2,71
13 Uhr	28	31	33	2,73	3,20	2,80
14 Uhr	22	33	22	2,69	3,18	2,73
15 Uhr	55	65	44	3,18	3,23	3,28
16 Uhr	35	40	70	2,77	3,02	2,72
17 Uhr	28	30	32	2,70	3,05	2,73
18 Uhr	18	36	19	2,67	3,19	2,66
19 Uhr	21	40	22	2,69	3,18	2,71
20 Uhr	15	36	19	2,70	3,05	2,72
21 Uhr	21	37	22	2,71	3,17	2,73
22 Uhr	12	35	18	2,71	3,12	2,67
23 Uhr	11	38	18	2,71	3,05	2,70

Tabelle A.5: Fahrplanabweichung und Energiebedarf der verschiedenen Fahrertypen zu allen Haltedauern des zweiten Szenarios

	Fahrplanabweichung [s]			Energiebedarf [kWh]		
	DF	EF	PF	DF	EF	PF
5 Uhr	98	104	35	3,59	2,98	3,68
6 Uhr	62	100	70	3,77	3,31	3,87
7 Uhr	77	92	92	3,52	2,99	2,99
8 Uhr	83	119	100	3,67	3,5	3,81
9 Uhr	83	94	82	4,24	3,53	3,86
10 Uhr	86	116	77	3,8	3,37	3,58
11 Uhr	81	60	60	3,79	3,14	3,14
12 Uhr	83	78	78	3,82	3,39	3,39
13 Uhr	81	111	79	4,16	3,65	4,29
14 Uhr	88	93	90	4,12	3,49	4,32
15 Uhr	88	175	82	3,84	2,89	3,39
16 Uhr	91	108	90	4,25	3,21	3,58
17 Uhr	82	114	63	3,75	3,09	3,27
18 Uhr	84	72	69	4,01	3,18	3,24
19 Uhr	82	104	76	3,91	3,26	3,98
20 Uhr	81	84	75	3,78	3,23	3,71
21 Uhr	78	93	79	4,22	3,64	3,82
22 Uhr	77	79	51	3,74	3,34	3,79
23 Uhr	87	86	86	4,02	3,44	3,44

Tabelle A.6: Fahrplanabweichung und Energiebedarf der Deep-RL-Agenten zu allen Haltedauern des zweiten Szenarios

	Fahrplanabweichung [s]			Energiebedarf [kWh]		
	KI 5 Uhr	KI 7 Uhr	KI 11 Uhr	KI 5 Uhr	KI 7 Uhr	KI 11 Uhr
5 Uhr	22	35	29	3,26	3,27	3,39
6 Uhr	18	19	16	3,34	3,22	3,55
7 Uhr	20	15	17	3,46	3,23	3,52
8 Uhr	21	25	27	3,71	3,31	3,53
9 Uhr	21	20	19	3,40	3,26	3,44
10 Uhr	23	31	26	3,40	3,27	3,41
11 Uhr	27	29	24	3,49	3,25	3,47
12 Uhr	21	29	24	3,51	3,32	3,44
13 Uhr	22	29	19	3,48	3,18	3,48
14 Uhr	26	32	29	3,44	3,29	3,47
15 Uhr	28	33	28	3,49	3,28	3,48
16 Uhr	26	32	28	3,38	3,27	3,32
17 Uhr	31	35	30	3,45	3,29	3,49
18 Uhr	23	27	26	3,43	3,31	3,44
19 Uhr	22	26	18	3,39	3,19	3,51
20 Uhr	25	27	24	3,41	3,36	3,54
21 Uhr	24	27	18	3,38	3,18	3,53
22 Uhr	25	22	22	3,34	3,31	3,52
23 Uhr	22	30	30	3,35	3,32	3,44

B Abbildungsverzeichnis

Abbildung 1.1:	Spannungsfeld von ÖPNV-Unternehmen.....	2
Abbildung 1.2:	Übersicht zur Struktur und der inhaltlichen Aufgliederung der Dissertation.....	16
Abbildung 2.1:	KDD-Prozess zur strukturierten Extraktion von Wissen aus Datenbeständen nach Fayyad [66].....	19
Abbildung 2.2:	Aufbau eines Entscheidungsbaums nach [77].....	21
Abbildung 2.3:	Aufbau eines künstlichen Neurons nach [77]	23
Abbildung 2.4:	MLP mit mehreren versteckten Schichten und einem Output nach [77]	25
Abbildung 2.5:	Schematischer Aufbau eines Convolutional Neural Networks nach [77]	26
Abbildung 2.6:	Schematischer Aufbau eines Long-Short-Term-Memory-Netzwerks nach [230].....	28
Abbildung 2.7:	Zusammenhang zwischen Modellgröße und Prädiktionsfehler für Trainings- und Testdatensatz nach [192]	32
Abbildung 2.8:	Interaktion von Agent und Umgebung im Reinforcement Learning nach [199].....	34
Abbildung 2.9:	Unterteilung von Reinforcement Learning Algorithmen nach [53]	36
Abbildung 2.10:	Zusammenspiel von Actor-und Critic-Netzwerken beim TD3-Algorithmus nach [86]	38
Abbildung 2.11:	Laufwiderstand auf Basis von Ausrollversuchen nach Springmann [194] mit zusätzlicher Variation des Fahrwiderstands. Darstellung nach [104]	43

Abbildung 2.12:	Äquivalente Steigung als Funktion des Bogenradius nach [131]	44
Abbildung 3.1:	Energiesparende Fahrweise mit Coasting- und Cruising-Anteilen nach [184]	46
Abbildung 3.2:	Paretokurve aus energie- und zeitoptimalen Fahrprofilen nach [236]	47
Abbildung 3.3:	Vergleich der im Stand der Technik und Wissenschaft vorgestellten Verfahren zur Berechnung energieeffizienter und pünktlicher Fahrprofile für Straßenbahnen	49
Abbildung 3.4:	Lösungsansatz zum Training und zum Test von Deep Reinforcement Learning Agenten mit Vergleich zum regulären Fahrgastbetrieb	55
Abbildung 3.5:	Vorgehensweise in der Dissertation	56
Abbildung 4.1:	Einordnung des vierten Kapitels im Lösungsansatz	57
Abbildung 4.2:	NET 2012 im Betriebshof (Bild: Philip Otto)	61
Abbildung 4.3:	KDD-Prozess zur Schaffung und Validierung der Datengrundlage.....	62
Abbildung 4.4:	Ergebnis der Zuordnung der Höhendaten zu den jeweiligen Messpunkten der Messstraßenbahn für die Linie S1 (a) und die Linie 4 (b).....	65
Abbildung 4.5:	Analyse des Laufwiderstands der Messstraßenbahn auf ebener Strecke inklusive einer Regressionsfunktion durch die Datenpunkte.....	70
Abbildung 4.6:	Vergleich der Regressionsfunktion des Laufwiderstandes der Messstraßenbahn mit Ausrollversuchen nach Springmann [194].....	71
Abbildung 4.7:	Analyse des Steigungswiderstands der Messstraßenbahn inklusive einer Regressionsfunktion durch die Datenpunkte und einem theoretischen Verlauf nach Gleichung 2-15 ...	73

Abbildung 4.8:	Analyse des Bogenwiderstands der Messstraßenbahn inklusive einer Regressionsfunktion durch die Datenpunkte und Literaturwerte	74
Abbildung 4.9:	Klassifikation der Fahrphasen auf einem einzelnen Streckenabschnitt zwischen der Welschneureuter Straße und dem Haus Bethlehem auf der Linie S1/S11.....	79
Abbildung 4.10:	Klassifikation aller Fahrten auf dem Streckenabschnitt Im Eichbäumle bis Waldstadt Glogauer Straße	79
Abbildung 5.1:	Einordnung des fünften Kapitels in den Lösungsansatz....	82
Abbildung 5.2:	Übersicht über die verschiedenen Modellierungsarten und Abtastfrequenzen zur Prädiktion des Energiebedarfs mit Black-Box-Modellen nach Tesar [207].....	87
Abbildung 5.3:	Struktur und Verarbeitungsschritte für die mesoskopische Modellierung nach Tesar [207]	91
Abbildung 5.4:	Auswirkung der Klassenanzahl auf die Verteilung der Datenpunkte der Histogramme	93
Abbildung 5.5:	Prädiktion der Traktionsleistung der Neuronalen Netze für eine Abtastfrequenz von 1 Hz nach Tesar [207]	98
Abbildung 5.6:	Prädiktion der Traktionsleistung der Neuronalen Netze für eine Abtastfrequenz von 2 Hz nach Tesar [207]	99
Abbildung 5.7:	Prädiktion der Traktionsleistung der Neuronalen Netze für eine Abtastfrequenz von 5 Hz nach Tesar [207]	99
Abbildung 5.8:	Prädiktion der Traktionsleistung der Neuronalen Netze für eine Abtastfrequenz von 10 Hz nach Tesar [207]	100
Abbildung 5.9:	Durchschnittlicher absoluter Fehler der Black-Box-Modelle in Abhängigkeit der Abtastfrequenz im Vergleich zum Evaluationsdatensatz der Messstraßenbahn	104
Abbildung 5.10:	Vergleich der Prädiktion mit mikroskopischem und mesoskopischen Modellierungsinput auf dem	

	Evaluationsdatensatz der Messstraßenbahn nach Tesar [207]	105
Abbildung 5.11:	Durchschnittliche Berechnungsdauer der Black-Box-Modelle	106
Abbildung 5.12:	Angepasstes Infrastrukturmodell mit kurvenradiusabhängiger Maximalgeschwindigkeit sowie einem unteren Geschwindigkeitsband nach Tesar [213]	110
Abbildung 5.13:	Grenzkennlinien für Beschleunigung und Verzögerung nach Tesar [213]	112
Abbildung 6.1:	Einordnung des sechsten Kapitels in den Lösungsansatz	119
Abbildung 6.2:	Linienverlauf und Haltestellen des ersten Szenarios von der Haltestelle Tivoli bis zur Haltestelle Kolpingplatz (erstellt mit ©Mapbox und ©OpenStreetMap)	121
Abbildung 6.3:	Geschwindigkeitsbeschränkungen des ersten Szenarios von der Haltestelle Tivoli bis zur Haltestelle Kolpingplatz nach Tesar [212]	121
Abbildung 6.4:	Durchschnittliche Haltedauern an den Haltestellen ohne im Fahrplan eingeplante Haltedauern im ersten Szenario nach Tesar [212]	122
Abbildung 6.5:	Linienverlauf und Haltestellen des zweiten Szenarios von der Haltestelle Glogauer Straße bis zur Haltestelle Europäische Schule (erstellt mit ©Mapbox und ©OpenStreetMap)	124
Abbildung 6.6:	Geschwindigkeitsbeschränkungen des zweiten Szenarios von der Haltestelle Glogauer Straße bis zur Haltestelle Europäische Schule nach Tesar [212]	125
Abbildung 6.7:	Durchschnittliche Haltedauern an den Haltestellen im zweiten Szenario nach Tesar [212]	126

Abbildung 6.8:	Linienverlauf und Haltestellen des dritten Szenarios von der Haltestelle Durlacher Tor bis zur Haltestelle Tivoli (erstellt mit ©Mapbox und ©OpenStreetMap).....	128
Abbildung 6.9:	Geschwindigkeitsbeschränkungen des dritten Szenarios von der Haltestelle Durlacher Tor bis zur Haltestelle Tivoli nach Tesar [212].....	128
Abbildung 6.10:	Fahrprofile der trainierten Deep-RL-Agenten im ersten Szenario zwischen Tivoli und Kolpingplatz nach Tesar [212]	131
Abbildung 6.11:	Fahrprofile der trainierten Deep-RL-Agenten im zweiten Szenario zwischen der Glogauer Straße und der Haltestelle Waldstadt Europäische Schule nach Tesar [212]	133
Abbildung 6.12:	Diskretisierung des Aktionsraums in fünf positive, fünf negative und eine neutrale Beschleunigungsmöglichkeit (a) und Änderungsmöglichkeiten der Beschleunigung (b). ..	135
Abbildung 6.13:	Eingrenzung des Lösungsraums für Dynamic Programming durch Implementierung einer oberen und unteren Schranke.....	137
Abbildung 6.14:	Durch Dynamic Programming ermitteltes Fahrprofil für die Nebenverkehrszeit des ersten Szenarios innerhalb der Grenzen.....	137
Abbildung 6.15:	Vergleich von KI, Fahrertypen und Dynamic Programming im ersten Szenario zu den drei Verkehrszeiten nach Tesar [212]	139
Abbildung 6.16:	Vergleich von KI, Fahrertypen und Dynamic Programming im zweiten Szenario zu den drei Verkehrszeiten nach Tesar [212]	141
Abbildung 6.17:	Klassifikation der Fahrweise der KI im Vergleich zu Fahrprofilen von Fahrern aus dem regulären Fahrgastbetrieb im ersten Szenario	143

Abbildung 6.18: Klassifikation der Fahrweise der KI im Gegensatz zu Fahrprofilen von Fahrern aus dem regulären Fahrgastbetrieb im zweiten Szenario.....	144
Abbildung 6.19: Fahrplanabweichungen und Energiebedarfe der Fahrprofile der Agenten zu trainierten und untrainierten Verkehrszeiten im ersten Szenario	146
Abbildung 6.20: Fahrplanabweichungen und Energiebedarfe der Fahrprofile der Agenten und Fahrertypen über alle Haltedauern von 5 bis 23 Uhr im ersten Szenario nach Tesar [212].....	148
Abbildung 6.21: Fahrplanabweichungen und Energiebedarfe der Fahrprofile der Agenten zu trainierten und untrainierten Verkehrszeiten im zweiten Szenario	149
Abbildung 6.22: Fahrplanabweichungen und Energiebedarfe der Fahrprofile der Agenten und Fahrertypen über alle Haltedauern von 5 bis 23 Uhr im zweiten Szenario nach Tesar [212]	151
Abbildung 6.23: Fahrprofile der Deep-RL-Agenten im dritten Szenario zwischen der Haltestelle Durlacher Tor und dem Tivoli nach Tesar [212]	153
Abbildung A.1: Einfluss der Designparameter auf die Prädiktion des Energiebedarfs	174
Abbildung A.2: Vergleich mikroskopische und mesoskopische MLP	176
Abbildung A.3: Vergleich mikroskopische und mesoskopische CNN.....	178
Abbildung A.4: Vergleich mikroskopische LSTM.....	179

C Tabellenverzeichnis

Tabelle 4.1:	Fahrzeugdaten des in Karlsruhe eingesetzten Messfahrzeugs nach [234]	60
Tabelle 4.2:	Ausgewählte Messgrößen für die Dissertation	63
Tabelle 4.3:	Regelbasierte Klassifikation der Fahrphasen mittels der Fahrhebelstellung und der Längsbeschleunigung des Fahrzeugs	76
Tabelle 4.4:	Vergleich der Übereinstimmung der drei Klassifikationsverfahren mit der regelbasierten Klassifikation anhand der Fahrhebeldaten	78
Tabelle 5.1:	Festgelegte Hyperparameter für das Training mikroskopischer Modelle	89
Tabelle 5.2:	Variable Hyperparameter der Grid Search für mikroskopische MLP	89
Tabelle 5.3:	Variable Hyperparameter der Grid Search für mikroskopische CNN	90
Tabelle 5.4:	Variable Hyperparameter der Grid Search für mikroskopische LSTM.....	90
Tabelle 5.5:	Übersicht über die Klassenanzahl der Histogramme für die einzelnen Merkmale.....	92
Tabelle 5.6:	Festgelegte Hyperparameter für das Training mesoskopischer Modelle	94
Tabelle 5.7:	Variable Hyperparameter der Grid Search für mesoskopische MLP	95
Tabelle 5.8:	Variable Hyperparameter der Grid Search für mesoskopische CNN	95

Tabelle 5.9:	Architektur und Ergebnisse der mikroskopischen Modellierung des Energiebedarfs sowie Vergleich mit Multi-Physik-Simulationsmodell nach Tesar [207].....	97
Tabelle 5.10:	Architektur und Ergebnisse der mesoskopischen Modellierung des Energiebedarfs nach Tesar [207]	102
Tabelle 5.11:	Hyperparameter für den TD3-Algorithmus nach Tesar [213]	118
Tabelle 6.1:	Betriebsparameter für Szenario 1 nach Tesar [212]	123
Tabelle 6.2:	Betriebsparameter für Szenario 2 nach Tesar [212]	127
Tabelle 6.3:	Betriebsparameter für Szenario 3	129
Tabelle 6.4:	Energiebedarf und Fahrplanabweichung der trainierten Agenten des ersten Szenarios nach Tesar [212]	131
Tabelle 6.5:	Energiebedarf und Fahrplanabweichung der trainierten Agenten des zweiten Szenarios nach Tesar [212]	134
Tabelle 6.6:	Fahrplanabweichungen und Energiebedarfe der verschiedenen Fahrertypen und Dynamic Programming des ersten Szenarios nach Tesar [212]	139
Tabelle 6.7:	Fahrplanabweichungen und Energiebedarfe der verschiedenen Fahrertypen und Dynamic Programming des zweiten Szenarios nach Tesar [212]	141
Tabelle 6.8:	Fahrplanabweichungen und Energiebedarfe der verschiedenen Agenten und Fahrertypen im dritten Szenario nach Tesar [212]	154
Tabelle A.1:	Energiebedarf und Fahrplanabweichung der trainierten Agenten des ersten Szenarios mit veränderter Rewardfunktion.....	180
Tabelle A.2:	Energiebedarf und Fahrplanabweichung der trainierten Agenten des zweiten Szenarios mit veränderter Rewardfunktion.....	180

Tabelle A.3:	Fahrplanabweichung und Energiebedarf der verschiedenen Fahrertypen zu allen Haltedauern des ersten Szenarios.	181
Tabelle A.4:	Fahrplanabweichung und Energiebedarf der Deep-RL-Agenten zu allen Haltedauern des ersten Szenarios.....	182
Tabelle A.5:	Fahrplanabweichung und Energiebedarf der verschiedenen Fahrertypen zu allen Haltedauern des zweiten Szenarios	183
Tabelle A.6:	Fahrplanabweichung und Energiebedarf der Deep-RL-Agenten zu allen Haltedauern des zweiten Szenarios	184

D Literaturverzeichnis

- [1] ABDEL-BASSET, M., ABDEL-FATAH, L., SANGAIAH, A. K.: *Metaheuristic Algorithms: A Comprehensive Review*. In: Sangaiah, A. K., Sheng, M., Zhang, Z. u. Xhafa, F. (Hrsg.): *Computational intelligence for multimedia big data on the cloud with engineering applications. Intelligent data centric systems*. London, Cambridge, MA: Academic Press an imprint of Elsevier 2018, S. 185–231. ISBN 978-0-128-13314-9. doi: 10.1016/B978-0-12-813314-9.00010-4
- [2] ABDULJABBAR, R., DIA, H., LIYANAGE, S., BAGLOEE, S. A.: *Applications of Artificial Intelligence in Transport: An Overview* Sustainability, Bd. 11, Nr. 189, S. 1–24, 2019. doi: 10.3390/su11010189
- [3] AGORA VERKEHRSWENDE: *Ein anderer Stadtverkehr ist möglich. Neue Chance für eine krisenfeste und klimagerechte Mobilität*, 2020. https://www.agora-verkehrswende.de/fileadmin/Projekte/2020/Covid19_Stadtverkehr/Agora-Verkehrswende_Einanderer-Stadtverkehr-ist-moeglich_1-1.pdf, abgerufen: 04.02.2022
- [4] ALBRECHT, A., HOWLETT, P., PUDNEY, P., VU, X., ZHOU, P.: *The key principles of optimal train control—Part 1: Formulation of the model, strategies of optimal type, evolutionary lines, location of optimal switching points* Transportation Research Part B: Methodological, Bd. 94,

- S. 482–508, 2016. ISSN 0191-2615. doi:
10.1016/j.trb.2015.07.023
- [5] ALBRECHT, A., HOWLETT, P., PUDNEY, P., VU, X., ZHOU, P.: *The key principles of optimal train control—Part 2: Existence of an optimal strategy, the local energy minimization principle, uniqueness, computational techniques*
Transportation Research Part B: Methodological, Bd. 94, S. 509–538, 2016. ISSN 0191-2615. doi:
10.1016/j.trb.2015.07.024
- [6] ALLEKOTTE, M., BERGK, F., BIEMANN, K., DEREGOWSKI CAROLIN, KNÖRR, W., ALTHAUS, H.-J., SUTTER, D., BERGMANN, T.: *Ökologische Bewertung von Verkehrsarten*. https://www.umweltbundesamt.de/sites/default/files/medien/479/publikationen/texte_156-2020_oekologische_bewertung_von_verkehrsarten_0.pdf, abgerufen: 04.02.2022
- [7] ALLOTTA, B., CHISCI, L., D'ADAMIO, P., PAPINI, S., PUGI, L.: *Design of an Automatic Train Operation (ATO) system based on CBTC for the management of driverless suburban railways*. 12th IMEKO TC10 Workshop on Technical Diagnostics New Perspectives in Measurements, Tools and Techniques for Industrial Applications. ITA; IMEKO 2013 Università di Firenze 2013, S. 84–89. ISBN 978-8-890-31498-8
- [8] AL-TURKI, M., RATROUT, N. T., RAHMAN, S. M., ASSI, K. J.: *Signalized Intersection Control in Mixed Autonomous and Regular Vehicles Traffic Environment—A Critical Review Focusing on Future Control*

- IEEE Access, Bd. 10, S. 16942–16951, 2022. doi: 10.1109/ACCESS.2022.3148706
- [9] ARENA, F., PAU, G., SEVERINO, A.: *A Review on IEEE 802.11p for Intelligent Transportation Systems*
Journal of Sensor and Actuator Networks, Bd. 9, Nr. 2, S. 22, 2020. doi: 10.3390/jsan9020022
- [10] ARULKUMARAN, K., DEISENROTH, M. P., BRUNDAGE, M., BHARATH, A. A.: *Deep Reinforcement Learning: A Brief Survey*
IEEE Signal Processing Magazine, Bd. 34, Nr. 6, S. 26–38, 2017. ISSN 1053-5888. doi: 10.1109/MSP.2017.2743240
- [11] AVENALI, A., CATALANO, G., GREGORI, M., MATTEUCCI, G.: *Rail versus bus local public transport services: A social cost comparison methodology*
Transportation Research Interdisciplinary Perspectives, Bd. 7, Nr. 100200, S. 1–15, 2020. ISSN 2590-1982. doi: 10.1016/j.trip.2020.100200
- [12] BAASCH, B., GROOS, J. C., ROTH, M. H.: *Sensorgestützte Anomaliedetektion zur Zustandsbewertung der Schiene mit Regelzügen*
ETR - Eisenbahntechnische Rundschau, Nr. 12, S. 32–35, 2018
- [13] BAASCH, B., HEUSEL, J., GROOS, J. C., SHANKAR, S.: *Eingebettete Zustandsüberwachung der Gleisinfrastuktur: Entwicklung und Erprobung von eingebetteten Multi-Sensor-Systemen für die kontinuierliche Zustandsüberwachung der Gleisinfrastuktur im operativen Betrieb*
Der Eisenbahningenieur EI, Nr. 12, S. 6–8, 2019

- [14] BABU, M., THEERTHALA, R. R., SINGH, A. K., BALADHURGESH, B. P., GOPALAKRISHNAN, B., KRISHNA, K. M., MEDASANI, S.: *Model Predictive Control for Autonomous Driving considering Actuator Dynamics*. 2019 American Control Conference (ACC). Piscataway, NJ: IEEE 2019, S. 1983–1989. ISBN 978-1-5386-7926-5. doi: 10.23919/ACC.2019.8814940
- [15] BAKER, C. J., CHAPMAN, L., QUINN, A., DOBNEY, K.: *Climate change and the railway industry: A review*. Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science, Bd. 224, Nr. 3, S. 519–528, 2010. ISSN 0954-4062. doi: 10.1243/09544062JMES1558
- [16] BELLMAN, R. E.: *Dynamic Programming*. Princeton University Press, Princeton, NJ 1957. ISBN 978-1-400-83538-6. doi: 10.1515/9781400835386
- [17] BERTSEKAS, D. P.: *Dynamic programming and optimal control*. Athena Scientific, Belmont, Mass., 3. ed. 2005. ISBN 1-886-52926-4
- [18] BIRR, K., JAMROZ, K., KUSTRA, W.: *Travel Time of Public Transport Vehicles Estimation*. Transportation Research Procedia, Bd. 3, S. 359–365, 2014. ISSN 2352-1465. doi: 10.1016/j.trpro.2014.10.016
- [19] BISHOP, C. M.: *Pattern Recognition and Machine Learning*. Springer New York, New York, NY, Softcover reprint of the original 1st edition 2006 (corrected at 8th printing 2009) 2006. ISBN 978-1-493-93843-8

- [20] BORTZ, J., SCHUSTER, C.: *Statistik für Human- und Sozialwissenschaftler*
Springer, Berlin, Heidelberg, 7., vollständig überarbeitete und
erweiterte Auflage 2010. ISBN 978-3-642-12769-4. doi:
10.1007/978-3-642-12770-0
- [21] BREIMAN, L.: *Random Forests*
Machine Learning, Bd. 45, Nr. 1, S. 5–32, 2001. ISSN 0885-6125.
doi: 10.1023/A:1010933404324
- [22] BRENNER, N., LAUBER, A., MEIER, C., REITMEIER, W., SAX, E.: *Requirements of Automated Vehicles and Depots for the Initial Step of Automated Public Transport*. In: Berns, K., Dressler, K., Kalmar, R., Stephan, N., Teutsch, R. u. Thul, M. (Hrsg.): *Commercial Vehicle Technology 2020/2021*. Proceedings. Wiesbaden: Springer Fachmedien Wiesbaden 2021, S. 15–26. ISBN 978-3-658-29716-9. doi: 10.1007/978-3-658-29717-6_2
- [23] BRENNER, N., ROSSEL, N., SAX, E.: *Automation Potentials in Public Transport based on a Depot Model*. Proceedings of the 8th International Conference on Vehicle Technology and Intelligent Transport Systems. SCITEPRESS - Science and Technology Publications 2022 - 2022, S. 216–225. ISBN 978-989-758-573-9. doi: 10.5220/0010998200003191
- [24] BRIGINSHAW, D.: *First commercial use of ATO over ETCS in London*, 2018. <https://www.railjournal.com/signalling/first-commercial-use-of-ato-over-etcs-in-london/>, abgerufen: 04.02.2022

- [25] BROCKMAN, G., CHEUNG, V., PETERSSON, L., SCHNEIDER, J., SCHULMAN, J., TANG, J., ZAREMBA, W.: *OpenAI Gym*, 2016. <https://arxiv.org/pdf/1606.01540>
- [26] BUCCHIARONE, A., BATTISTI, S., MARCONI, A., MALDACEA, R., PONCE, D. C.: *Autonomous Shuttle-as-a-Service (ASaaS): Challenges, Opportunities, and Social Implications*
Institute of Electrical and Electronics Engineers (IEEE) 2020.
doi: 10.36227/techrxiv.11629215.v1
- [27] BUHMANN, M. D., MELVILLE, P., SINDHWANI, V., QUADRIANTO, N., BUNTINE, W. L., TORGO, L., ZHANG, X., STONE, P., STRUYF, J., BLOCCKEEL, H., DRIESSENS, K., MIIKKULAINEN, R., WIEWIORA, E., PETERS, J., TEDRAKE, R., ROY, N., MORIMOTO, J., FLACH, P. A., FÜRNKRANZ, J.: *Random Forests*. In: Sammut, C. u. Webb, G. I. (Hrsg.): *Encyclopedia of Machine Learning*. SpringerLink Bücher. Boston, MA: Springer US 2010, S. 828. ISBN 978-0-387-30768-8. doi: 10.1007/978-0-387-30164-8_695
- [28] BUNDESMINISTERIUM DER JUSTIZ: Personenbeförderungsgesetz in der Fassung der Bekanntmachung vom 8. August 1990 (BGBl. I S. 1690), das zuletzt durch Artikel 1 des Gesetzes vom 16. April 2021 (BGBl. I S. 822) geändert worden ist. <https://www.gesetze-im-internet.de/pbefg/BJNR002410961.html>, abgerufen: 26.10.2022
- [29] BUNDESMINISTERIUM FÜR UMWELT, NATURSCHUTZ UND NUKLEARE SICHERHEIT: *Der Klimaschutzplan 2050 - Die deutsche Klimaschutz-*

- langfriststrategie*, 2016. <https://www.bmu.de/themen/klimaschutz-anpassung/klimaschutz/nationale-klimapolitik/klimaschutzplan-2050>, abgerufen: 04.02.2022
- [30] BUNDESREGIERUNG: *Klimaschonender Verkehr*. <https://www.bundesregierung.de/breg-de/themen/klimaschutz/klimaschonender-verkehr-1794672>, abgerufen: 04.02.2022
- [31] BUNDESREGIERUNG: *Klimaschutzprogramm 2030 der Bundesregierung zur Umsetzung des Klimaschutzplans 2050*, 2019. https://www.bmel.de/SharedDocs/Downloads/DE/_Landwirtschaft/Klimaschutz/Klimaschutzprogramm2030.pdf?__blob=publicationFile&v=3, abgerufen: 04.02.2022
- [32] BUNDESREGIERUNG: *Zusätzliche Milliardenhilfen für den ÖPNV. Gemeindeverkehrsfinanzierungsgesetz*, 2019. <https://www.bundesregierung.de/breg-de/themen/klimaschutz/gvfg-1688836>, abgerufen: 04.02.2022
- [33] CALIN, O. L.: *Deep learning architectures. A mathematical approach*
Springer, Cham, Switzerland 2020. ISBN 978-3-030-36720-6.
doi: 10.1007/978-3-030-36721-3
- [34] CHEN, Y., WU, G., SUN, R., DUBEY, A., LASZKA, A., PUGLIESE, P.: *A Review and Outlook on Energy Consumption Estimation Models for Electric Vehicles*
SAE International Journal of Sustainable Transportation, Energy, Environment, & Policy, Bd. 2, Nr. 1, S. 79–96, 2021. ISSN 2640-6438. doi: 10.4271/13-02-01-0005

- [35] CHEVRIER, R., PELLEGRINI, P., RODRIGUEZ, J.: *Energy saving in railway timetabling: A bi-objective evolutionary approach for computing alternative running times*
Transportation Research Part C: Emerging Technologies, Bd. 37, S. 20–41, 2013. ISSN 0968-090X. doi: 10.1016/j.trc.2013.09.007
- [36] Choi, Cho, Kim: *Power Demand Forecasting using Long Short-Term Memory (LSTM) Deep-Learning Model for Monitoring Energy Sustainability*
Sustainability, Bd. 12, Nr. 1109, S. 1–14, 2020. doi: 10.3390/su12031109
- [37] CHRISTOFOROU, Z., CHANDAKAS, E., KAPARIAS, I.: *Investigating the Impact of Dwell Time on the Reliability of Urban Light Rail Operations*
Urban Rail Transit, Bd. 6, Nr. 2, S. 116–131, 2020. ISSN 2199-6687. doi: 10.1007/s40864-020-00128-1
- [38] CISMARU, D. C., DRIGHICIU, M. A., NICOLA, D. A.: *SIMULINK model for study of energy efficient train control*. 2014 International Conference on Applied and Theoretical Electricity (ICATE 2014). Craiova, Romania, 23 - 25 October 2014. Piscataway, NJ: IEEE 2014, S. 1–4. ISBN 978-1-4799-4161-2. doi: 10.1109/ICATE.2014.6972685
- [39] CONTINENTAL ENGINEERING SERVICES: *Solutions for the Railway Industry*, 2021. <https://conti-engineering.com/domains-and-markets/railway/>, abgerufen: 04.02.2022

- [40] COREA, F.: *An Introduction to Data. Everything You Need to Know About AI, Big Data and Data Science*
Springer, Cham 2019. ISBN 978-3-030-04468-8. doi:
10.1007/978-3-030-04468-8
- [41] DANKWA, S., ZHENG, W.: *Twin-Delayed DDPG: A Deep Reinforcement Learning Technique to Model a Continuous Movement of an Intelligent Robot Agent*. Proceedings of the 3rd International Conference on Vision, Image and Signal Processing. ACM Digital Library. New York, NY, United States: Association for Computing Machinery 2019, S. 1–5. ISBN 978-1-450-37625-9. doi:
10.1145/3387168.3387199
- [42] DASSALUT SYSTÈMES DEVELOPERS: *DYMOLA (Dynamic Modeling Laboratory) Systems Engineering, Multi-Engineering-Modellierung und -Simulation auf Basis von Modelica und FMI* [Computer Software]
Dassault Systèmes 2022. <https://www.3ds.com/de/produkte-und-services/catia/produkte/dymola/>, abgerufen: 26.10.2022
- [43] DAVIDSSON, P., HAJINASAB, B., HOLMGREN, J., JEVINGER, Å., PERSSON, J.: *The Fourth Wave of Digitalization and Public Transport: Opportunities and Challenges*
Sustainability, Bd. 8(12), Nr. 1246, S. 1–16, 2016. doi:
10.3390/su8121248
- [44] DB NETZE: *Infrastrukturzustands- und -entwicklungsbericht 21 - Leistungs- und Finanzierungsvereinbarung, 2022.*
<https://www.eba.bund.de/SharedDocs/Downloads/DE/Finan->

- zierung/IZB/IZB_2021.pdf;jsessionid=20EDC416FBF1741AE35C1F184BF042B6.live21301?_blob=publicationFile&v=2, abgerufen: 23.08.2022
- [45] DEUTSCHE BAHN: *Abbruch von La in EBUla und künftige La-Datenbereitstellung*, 2014. https://www.dbnetze.com/infrastruktur-de/Kundeninformationen/2014_49_Abbruch_EBUla_1441234, abgerufen: 24.08.2022
- [46] DEUTSCHES INSTITUT FÜR NORMUNG E.V. DIN, Nr. 12299:2009, Bd. 45.060.20. *Bahnanwendungen - Fahrkomfort für Fahrgäste - Messung und Auswertung*
- [47] DEUTSCHES INSTITUT FÜR NORMUNG E.V. DIN, Nr. 50591:2019, Bd. 45.060.10; 2019. *Bahnanwendungen - Fahrzeuge - Spezifikation und Überprüfung des Energieverbrauchs*
- [48] DEUTSCHES ZENTRUM FÜR LUFT- UND RAUMFAHRT E.V., DEUTSCHES INSTITUT FÜR WIRTSCHAFTSFORSCHUNG, KRAFTFAHRT-BUNDESAMT: *Verkehr in Zahlen 2020/2021*, 2020. https://www.bmvi.de/SharedDocs/DE/Publikationen/G/verkehr-in-zahlen-2020-pdf.pdf?_blob=publicationFile, abgerufen: 04.02.2022
- [49] DEUTSCHLAND MOBIL 2030: *Pilotprojekt gestartet: Darmstadt teste ferngesteuerte und automatisierte Tram*, 2019. <https://www.deutschland-mobil-2030.de/blog/pilotprojekt-gestartet-darmstadt-testet-ferngesteuerte-und-automatisierte-tram>, abgerufen: 04.02.2022
- [50] DI PALMA, C., GALDI, V., CALDERARO, V., LUCA, F. de: *Driver Assistance System for Trams: Smart Tram in Smart Cities*. Conference

- proceedings 2020 IEEE International Conference on Environment and Electrical Engineering and 2020 IEEE Industrial and Commercial Power Systems Europe (EEEIC/I & CPS Europe). 9-12 June, 2020, Madrid, Spain : the 2020 edition will be held on scheduled days from 09th to 12th June 2020 in web streaming. Piscataway, NJ: IEEE 2020, S. 1–6. ISBN 978-1-7281-7455-6. doi: 10.1109/EEEIC/ICPSEurope49358.2020.9160780
- [51] DÖBEL, I., LEIS, M., MOLINA VOGELSANG, M., AL, E.: *Maschinelles Lernen. Eine Analyse zu Kompetenzen, Forschung und Anwendung*, 2018. https://www.bigdata-ai.fraunhofer.de/content/dam/bigdata/de/documents/Publikationen/BMBF_Fraunhofer_ML-Ergebnisbericht_Gesamt.pdf, abgerufen: 04.02.2022
- [52] DOMOKOS, D.: *Bosch's innovative collision avoidance system is tested on a tram line in Debrecen*, 2021. https://boschmediaservice.hu/en/press_release/bosch_debrecen_tram-308.html, abgerufen: 04.02.2022
- [53] Dong, H., Ding, Z. u. Zhang, S. (Hrsg.): *Deep Reinforcement Learning. Fundamentals, Research and Applications*. Springer eBook Collection
Springer Singapore Pte. Limited, Singapore, 1st ed. 2020
- [54] DURACIK, M., KRSÁK, E., MESKO, M., RUZBARSKY, J.: *Software architecture of Automatic Train Operation*. Informatics 2019. IEEE 15th International Scientific Conference on Informatics : proceedings : November 20-22, 2019, Poprad, Slovakia. Piscataway, NJ: IEEE

- 2019, S. 51–54. ISBN 978-1-7281-3180-1. doi: 10.1109/Informatics47936.2019.9119327
- [55] DÜRRSCHMIDT, G.: *Neue Erkenntnisse zu Fahrdynamik und Energieverbrauch von Straßenbahnen durch Nutzung eines Langzeitversuchsträgers*, Internationaler Fachverlag für Wissenschaft & Praxis u. Technische Universität Dresden, Dissertation. Dresden 2019
- [56] DÜRRSCHMIDT, G., HARTER, M., BEITELSCHMIDT, M.: *5 Jahre Messstraßenbahn Dresden – Erfahrungen und Auswerteprojekte* Eisenbahntechnische Rundschau (ETR), Nr. 06, S. 36–41, 2014
- [57] ECKE, L., CHLOND, B., MAGDOLEN, M., HILGERT, T., VORTISCH, P.: *Deutsches Mobilitätspanel (MOP) – Wissenschaftliche Begleitung und Auswertungen Bericht 2018/2019: Alltagsmobilität und Fahrleistung*, 2020. doi: 10.5445/IR/1000105940/V2
- [58] EICHNER, D., UHRIG, B.: *Innovationen in CBTC-Anwendungen* SIGNAL+DRAHT, Bd. 113, Nr. 9, S. 34–44, 2021
- [59] ELLER, M.: *Prädiktiver Betrieb von Multi-Hybrid-Antrieben im SPNV*, Karlsruher Institut für Technologie, Dissertation. Karlsruhe 2019. doi: 10.5445/IR/1000089339
- [60] ENCARNACAO, J.: *Machine Learning. An Artificial Intelligence Approach* Springer Berlin Heidelberg, Berlin/Heidelberg, 1st ed. 1983. ISBN 978-3-662-12405-5
- [61] ESCHBACH, R.: *Formalizing and Analyzing System Requirements of Automatic Train Operation over ETCS Using Event-B*. In: Raschke, A. u. Méry, D. (Hrsg.): *Rigorous State-Based Methods*.

- 8th International Conference, ABZ 2021, Ulm, Germany, June 9–11, 2021, Proceedings. Springer eBook Collection, Bd. 12709. Cham: Springer International Publishing; Imprint Springer 2021, S. 137–142. ISBN 978-3-030-77542-1. doi: 10.1007/978-3-030-77543-8_13
- [62] EUROPÄISCHE UNION: *Verordnung (EG) Nr. 1370/2007* des Europäischen Parlaments und des Rates vom 23. Oktober 2007 über öffentliche Personenverkehrsdienste auf Schiene und Straße, 2007. https://eur-lex.europa.eu/legal-content/DE/TXT/?uri=uriserv:OJ.L_.2007.315.01.0001.01.DEU, abgerufen: 26.10.2022
- [63] EUROPEAN RAILWAY AGENCY: *Introduction to ETCS Braking Curves*, 2020. https://www.era.europa.eu/sites/default/files/activities/docs/introduction_to_etcs_braking_curves_en.pdf, abgerufen: 22.07.2022
- [64] FAHEY, L., NARAYANAN, V. K.: *Macroenvironmental analysis for strategic management*
West Publ. Comp, St. Paul 1986. ISBN 0-314-85233-6
- [65] FARIS, W. F., RAKHA, H. A., KAFIFY, R. I., IDRES, M., ELMOSELY, S.: *Vehicle fuel consumption and emission modelling: an in-depth literature review*
International Journal of Vehicle Systems Modelling and Testing, Bd. 6, Nr. 3/4, S. 318–395, 2011. ISSN 1745-6436. doi: 10.1504/IJVSMT.2011.044232
- [66] FAYYAD, U., PIATETSKY-SHAPIRO, G., SMYTH, P.: *From Data Mining to Knowledge Discovery in Databases*

- AI Magazine, Bd. 17, Nr. 3, S. 37–54, 1996. ISSN 2371-9621. doi: 10.1609/aimag.v17i3.1230
- [67] FEDUS, W., RAMACHANDRAN, P., AGARWAL, R., BENGIO, Y., LAROCHELLE, H., ROWLAND, M., DABNEY, W.: *Revisiting fundamentals of experience replay*
ICML'20: Proceedings of the 37th International Conference on Machine Learning, S. 3061–3071, 2020
- [68] FEL, L., ZINNER, C., KADIOFSKY, T., POINTNER, W., WECHSELBAUM, J., REISNER, C.: *ODAS - An anti-collision assistance system for light rail vehicles and further development*
Proceedings of the 7th Transport Research Arena, TRA 2018, Vienna, Austria, S. 1–9, 2018. doi: 10.5281/zenodo.1451549
- [69] FELDKAMP, N., BERGMANN, S., STRASSBURGER, S.: *Simulation-Based Deep Reinforcement Learning For Modular Production Systems*. 2020 Winter Simulation Conference (WSC). Piscataway, NJ: IEEE 2020, S. 1596–1607. ISBN 978-1-7281-9499-8. doi: 10.1109/WSC48552.2020.9384089
- [70] FETENE, G. M., KAPLAN, S., MABIT, S. L., JENSEN, A. F., PRATO, C. G.: *Harnessing big data for estimating the energy consumption and driving range of electric vehicles*
Transportation Research Part D: Transport and Environment, Bd. 54, S. 1–11, 2017. ISSN 1361-9209. doi: 10.1016/j.trd.2017.04.013
- [71] FIORI, C., AHN, K., RAKHA, H. A.: *Power-based electric vehicle energy consumption model: Model development and validation*

- Applied Energy, Bd. 168, S. 257–268, 2016. ISSN 0306-2619.
doi: 10.1016/j.apenergy.2016.01.097
- [72] FLEGE, D., ZERBAN, F., STOFFREGEN, M., WESTERNBERGER, P., MÖBIUS, B., WOLFF, O., LAWRENZ, M.: *Der Schiene jetzt Priorität geben. Drei Kernforderungen zur Bundestagswahl 2021*, 2021.
<https://www.vdv.de/bundestagswahl-2021-forderungen-der-bahnverbaende.aspx>, abgerufen: 04.02.2022
- [73] FOLKERS, A., RICK, M., BUSKENS, C.: *Controlling an Autonomous Vehicle with Deep Reinforcement Learning*. IV19. 30th IEEE Intelligent Vehicles Symposium : 9-12 June 2019, Paris. Piscataway, New Jersey: IEEE 2019, S. 2025–2031. ISBN 978-1-7281-0560-4. doi: 10.1109/IVS.2019.8814124
- [74] FÖLLINGER, O.: *Regelungstechnik. Einführung in die Methoden und ihre Anwendung*
VDE Verlag, Berlin, 13., überarbeitete Auflage 2022. ISBN 978-3-8007-5519-6
- [75] FRANKE, R., TERWIESCH, P., MEYER, M.: *An algorithm for the optimal control of the driving of trains*. Proceedings of the 39th IEEE Conference on Decision and Control. December 12 - 15, 2000, Sydney Convention and Exhibition Centre, Sydney, Australia. Piscataway, NJ: IEEE Customer Service 2000, S. 2123–2128. 0-7803-6638-7. doi: 10.1109/CDC.2000.914108
- [76] FRANKE, U., PFEIFFER, D., RABE, C., KNOEPEL, C., ENZWEILER, M., STEIN, F., HERRTWICH, R. G.: *Making Bertha See*. 2013 IEEE International Conference on Computer Vision Workshops. IEEE

- 2013, S. 214–221. ISBN 978-1-4799-3022-7. doi: 10.1109/IC-CVW.2013.36
- [77] FROCHTE, J.: *Maschinelles Lernen. Grundlagen und Algorithmen in Python*
Hanser, München 2018. ISBN 3-446-45291-5
- [78] FUJIMOTO, S., VAN HOOF, H., MEGER, D.: *Addressing Function Approximation Error in Actor-Critic Methods*, Bd. ICML'18: Proceedings of the 35th International Conference on Machine Learning, S. 1587–1596, 2018
- [79] FUMEO, E., ONETO, L., ANGUIA, D.: *Condition Based Maintenance in Railway Transportation Systems Based on Big Data Streaming Analysis*
Procedia Computer Science, Bd. 53, S. 437–446, 2015. ISSN 1877-0509. doi: 10.1016/j.procs.2015.07.321
- [80] GARCÍA-GARRE, A., GABALDÓN, A.: *Analysis, Evaluation and Simulation of Railway Diesel-Electric and Hybrid Units as Distributed Energy Resources*
Applied Sciences, Bd. 9, Nr. 3605, S. 1–14, 2019. doi: 10.3390/app9173605
- [81] GÉRON, A.: *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow. Concepts, tools, and techniques to build intelligent systems*
O'Reilly, Boston, Second edition 2019. ISBN 978-1-492-03261-8
- [82] GERRARD, J.: *Bombardier's driver assistance system for trams*
AusRAIL PLUS 2017, Rail's Digital Revolution, 21-23 November 2017, Brisbane, Qld, Australia, 2017

- [83] GHOFRANI, F., HE, Q., GOVERDE, R. M., LIU, X.: *Recent applications of big data analytics in railway transportation systems: A survey* Transportation Research Part C: Emerging Technologies, Bd. 90, S. 226–246, 2018. ISSN 0968-090X. doi: 10.1016/j.trc.2018.03.010
- [84] GOODFELLOW, I., BENGIO, Y., COURVILLE, A.: *Deep learning* The MIT Press, Cambridge, Massachusetts, London, England 2016. ISBN 978-0-262-33737-3
- [85] GUNSELMANN, W.: *Technologies for increased energy efficiency in railway systems*. 2005 European Conference on Power Electronics and Applications. Dresden, Germany, 11 - 14 September 2005. Piscataway, NJ: IEEE Service Center 2005, 1-10. ISBN 90-75815-09-3. doi: 10.1109/EPE.2005.219712
- [86] GUO, S., ZHANG, X., ZHENG, Y., DU, A. Y.: *An Autonomous Path Planning Model for Unmanned Ships Based on Deep Reinforcement Learning* Sensors (Basel, Switzerland), Bd. 20, Nr. 426, S. 1–35, 2020. doi: 10.3390/s20020426
- [87] HAAHR, J. T., PISINGER, D., SABBAGHIAN, M.: *A dynamic programming approach for optimizing train speed profiles with speed restrictions and passage points* Transportation Research Part B: Methodological, Bd. 99, S. 167–182, 2017. ISSN 0191-2615. doi: 10.1016/j.trb.2016.12.016
- [88] HASANKHANI, A., TANG, Y., VANZWIETEN, J., SULTAN, C.: *Comparison of Deep Reinforcement Learning and Model Predictive Control for*

- Real-Time Depth Optimization of a Lifting Surface Controlled Ocean Current Turbine*. 2021 IEEE Conference on Control Technology and Applications (CCTA). IEEE 2021 - 2021, S. 301–308. ISBN 978-1-6654-3643-4. doi: 10.1109/CCTA48906.2021.9659089
- [89] HECK, J.: *Zur Simulation des Rad-Schiene-Verschleißes bei Straßenbahnen*
KIT Scientific Publishing, Karlsruhe. ISBN 978-3-7315-0443-6. doi: 10.5445/KSP/1000049865
- [90] HEESS, N., TB, D., SRIRAM, S., LEMMON, J., MEREL, J., WAYNE, G., TASSA, Y., EREZ, T., WANG, Z., ESLAMI, S. M. A., RIEDMILLER, M., SILVER, D.: *Emergence of Locomotion Behaviours in Rich Environments*, 2017. <https://arxiv.org/pdf/1707.02286>, abgerufen: 15.06.2022
- [91] HESSEL, M., MODAYIL, J., VAN HASSELT, H., SCHAUL, T., OSTROVSKI, G., DABNEY, W., HORGAN, D., PIOT, B., AZAR, M., SILVER, D.: *Rainbow: Combining Improvements in Deep Reinforcement Learning*
Proceedings of the AAAI Conference on Artificial Intelligence, Bd. 32, Nr. 1, 2018. ISSN 2159-5399. doi: 10.1609/aaai.v32i1.11796
- [92] HILMER, L.: *Data Mining zur Quantifizierung des Einflusses der Fahrgastzahl auf Energieverbrauch und Fahrdynamik*, Karlsruher Institut für Technologie, Bachelorarbeit. Karlsruhe 2020
- [93] HOCHREITER, S., SCHMIDHUBER, J.: *Long short-term memory*
Neural computation, Bd. 9, Nr. 8, S. 1735–1780, 1997. ISSN 0899-7667. doi: 10.1162/neco.1997.9.8.1735

- [94] HÖFCHEN, T.: *Analyse des Potenzials der energiesparenden Fahrweise mit Hilfe von Data Mining Verfahren*, Karlsruher Institut für Technologie, Bachelorarbeit. Karlsruhe 2020
- [95] HOFMANN, M.: *Siemens Mobility und ViP Potsdam auf dem Weg zur autonomen Tram*
bahn manager Magazin, Nr. 02, S. 1–3, 2020
- [96] HOFMANN, M., KLIER, C., LAST, H.: *Die erste autonome Tram von Siemens. Erfahrungen und Herausforderungen beim Forschungsprojekt mit der ViP Verkehrsbetrieb Potsdam GmbH*
ZEV Rail, Sonderheft Tagungsband 45. Tagung "Moderne Schienenfahrzeuge" Graz 2019, Bd. 143, S. 188–195, 2019
- [97] HORNIK, K., STINCHCOMBE, M., WHITE, H.: *Multilayer feedforward networks are universal approximators*
Neural Networks, Bd. 2, Nr. 5, S. 359–366, 1989. ISSN 0893-6080. doi: 10.1016/0893-6080(89)90020-8
- [98] HUNN, S., ZÜGER, S., NERLICH, I., SCHLATTER, C., Wolter Klaus Ulrich: *Onboard Monitoring in der Schweiz, ein Gemeinschaftswerk dreier Bahnen*
ZEV Rail, Bd. 144, Nr. 4, S. 40–46, 2020
- [99] HURZLMEIER, J.: *Auswahl und Implementierung einer Datenbank für Langzeitmessdaten*, Karlsruher Institut für Technologie, Bachelorarbeit. Karlsruhe 2019
- [100] HYDE, P., ULIANOV, C., LIU, J., BANIC, M., SIMONOVIC, M., RISTIC-DURRANT, D.: *Use cases for obstacle detection and track intrusion detection systems in the context of new generation of railway traffic management systems*

- Proceedings of the Institution of Mechanical Engineers, Part F:
Journal of Rail and Rapid Transit, Bd. 236, Nr. 2, S. 149–158,
2022. ISSN 0954-4097. doi: 10.1177/09544097211041020
- [101] ICF CONSULTING SERVICE LIMITED: *Sozialbedingungen in Unternehmen des öffentlichen Personennahverkehrs in Europa*, 2016.
https://verkehr.verdi.de/++file++5c9b5212e999fb6c89d9fb16/download/social-conditions-UPT-companies-DE_160926.pdf, abgerufen: 04.02.2022
- [102] ICLODEAN, C., CORDOS, N., VARGA, B. O.: *Autonomous Shuttle Bus for Public Transportation: A Review*
Energies, Bd. 13, Nr. 11(2917), S. 1–45, 2020. ISSN 1996-1073.
doi: 10.3390/en13112917
- [103] IEC, Nr. 62290-1:2014, Bd. 45.060.01; 2014. *Railway Applications - Urban guided transport management and command/control systems*
- [104] IHME, J.: *Schienefahrzeugtechnik*
Springer Vieweg, Wiesbaden, 1. Auflage 2016. ISBN 978-3-658-13540-9. doi: 10.1007/978-3-658-13541-6
- [105] INSTITUTE OF AUTOMOTIVE ENGINEERING DARMSTADT: *Machbarkeitsstudie zur Automatisierung und Assistenzsystemen der Straßenbahn*, 2020. https://www.fzd.tu-darmstadt.de/forschung/research_projects_fzd/maas_fzd/index.de.jsp, abgerufen: 04.02.2022

- [106] INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS. *IEEE Standard for Communications-Based Train Control (CBTC) Performance and Functional Requirements*
- [107] INTERNATIONALES VERKEHRSWESSEN: *AStrid-Projekt "Autonome Straßenbahn im Depot" startet*, 2019. <https://www.internationales-verkehrswesen.de/astrid-projekt-autonome-strassenbahn-im-depot-startet/>, abgerufen: 04.02.2022
- [108] IRPAN, A.: *Deep Reinforcement Learning Doesn't Work Yet*, 2018. <https://www.alexirpan.com/2018/02/14/rl-hard.html>, abgerufen: 06.02.2022
- [109] JAIN, A., PATEL, H., NAGALAPATTI, L., GUPTA, N., MEHTA, S., GUTTULA, S., MUJUMDAR, S., AFZAL, S., SHARMA MITTAL, R., MUNIGALA, V.: *Overview and Importance of Data Quality for Machine Learning Tasks*. Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York, NY, USA: ACM 2020, S. 3561–3562. 9781450379984. doi: 10.1145/3394486.3406477
- [110] JANICKI, J., REINHARD, H., RÜFFER, M.: *Schienefahrzeugtechnik* BVF Bahn-Fachverl., Berlin, 3., überarb. und erw. Aufl. 2013. ISBN 978-3-943-21407-9
- [111] JARDINE, A. K., LIN, D., BANJEVIC, D.: *A review on machinery diagnostics and prognostics implementing condition-based maintenance*
Mechanical Systems and Signal Processing, Bd. 20, Nr. 7, S. 1483–1510, 2006. ISSN 0888-3270. doi: 10.1016/j.ymsp.2005.09.012

- [112] JUNG, H.-S., RÜFFER, M., SCHINDLER, C.: *Fahrerassistenzsysteme für die Straßenbahn. Eine Umfrage bei Verkehrsbetrieben*
Der Nahverkehr, Nr. 7+8, 26-35, 2018
- [113] JUNGCLAUSSEN, H.: *Kausale Informatik. Einführung in Die Lehre Vom Aktiven Sprachlichen Modellieren Durch Mensch und Computer*
Deutscher Universitäts Verlag, Wiesbaden 2001. ISBN 978-3-322-81220-9
- [114] KARLSRUHER INSTITUT FÜR TECHNOLOGIE: *Münchner Stadtbus der Zukunft fährt in Kolonne*, 2021.
https://www.kit.edu/kit/pi_2021_050_munchner-stadtbus-der-zukunft-fahrt-in-kolonne.php, abgerufen: 23.08.2022
- [115] KARLSRUHER VERKEHRSVERBUND: *KVV Kursbuch 2021*, 2021.
https://www.kvv.de/fileadmin/user_upload/kvv/Daten/Fahrplaene_Netzplaene/KVV_Kursbuch_A4_2021.pdf, abgerufen: 11.04.2022
- [116] KATSAROS, G.: *ÖPNV-Kundenzufriedenheit in Münster*.
https://www.lwl.org/LWL/Kultur/Westfalen_Regional/Verkehr/OPNV_Muenster, abgerufen: 04.02.2022
- [117] KIM, M., HAN, D.-K., PARK, J.-H., KIM, J.-S.: *Motion Planning of Robot Manipulators for a Smoother Path Using a Twin Delayed Deep Deterministic Policy Gradient with Hindsight Experience Replay*
Applied Sciences, Bd. 10(2), Nr. 575, S. 1–15, 2020. doi: 10.3390/app10020575
- [118] KINGMA, D. P., BA, J.: *Adam: A Method for Stochastic Optimization*, 2014. <https://arxiv.org/pdf/1412.6980>

- [119] KROLL, A.: *Grey-Box Models: Concepts and Application* International Conference on Computational Intelligence for Modelling, Control and Automation; New Frontiers in Computational Intelligence and its Applications, S. 42–51, 2000
- [120] KUBIN, J., FERKOVA, Z.: *Influence of driving style of a tram driver on the tram's energy consumption*. 2015 International Conference on Electrical Drives and Power Electronics (EDPE 2015). Tatranská Lomnica, Slovakia, 21-23 September 2015. Piscataway, NJ: IEEE 2015, S. 417–421. ISBN 978-1-467-37376-0. doi: 10.1109/EDPE.2015.7325331
- [121] KUSCHE, M., GEIPERT, S.: *Application for the UIC Sustainability Awards 2010. Category: "Energy Efficiency and CO2"*, 2010. https://www.uic-environment.org/2010/IMG/pdf/dbag_eco-trainbook_ostermayer_100430.pdf, abgerufen: 24.08.2022
- [122] LAGAY, R., ADELL, G. M.: *The Autonomous Train: a game changer for the railways industry*. Proceedings of 2018 16th International Conference on Intelligent Transport System Telecommunications (ITST). October 15-17, 2018, Lisboa, Portugal. Piscataway, NJ: IEEE 2018, S. 1–5. ISBN 978-1-5386-5544-3. doi: 10.1109/ITST.2018.8566728
- [123] LANG, H. P., FÜRSTENAU, F., Heerdegen Björn: *Antworten auf die Herausforderungen der Deutschen Bahn. Neue Konzepte für das Flottenmanagement, Beschaffungs- und Technikstrategie für Schienenfahrzeuge* ZEV Rail, Sonderheft Tagungsband 43. Tagung "Moderne Schienenfahrzeuge" Graz 2016, Bd. 140, S. 8–17, 2016

- [124] LARRANAGA, M., ANSELM, J., Ayesta, Urtzi, Jacko Peter, ROMO, A.: *Optimization techniques applied to railway systems*
HAL open science, 2013
- [125] LAUBER, A., SAX, E., WIEDEMANN, M.: *Autonomes Fahren auf dem Busbetriebshof*
ATZ - Automobiltechnische Zeitschrift, Bd. 120, Nr. 6, S. 74–77, 2018. ISSN 0001-2785. doi: 10.1007/s35148-018-0047-y
- [126] LAUD, A.: *Theory and application of reward shaping in reinforcement learning*, University of Illinois at Urbana-Champaign, Dissertation. Champaign, Illinois 2004
- [127] LEHELLE, S. A., MOUNEIMNE, Z. S.: *OptiDrive: a practical approach for the calculation of energy-optimised operating speed profiles*. IET Conference on Railway Traction Systems (RTS 2010). IET 2010, S. 23. ISBN 978-1-84919-211-8. doi: 10.1049/ic.2010.0029
- [128] LECHLEITNER, C., Newsely Gerald, ZINNER, C.: *Die Straßenbahn lernt sehen- Innovationen im Bereich Straßen- und Stadtbahnen*
ZEV Rail, Sonderheft Tagungsband 42. Tagung "Moderne Schienenfahrzeuge" Graz 2014, Bd. 138, S. 145–152, 2014
- [129] LECUN, Y., BENGIO, Y., HINTON, G.: *Deep learning*
Nature, Bd. 521, Nr. 7553, S. 436–444, 2015. doi: 10.1038/nature14539
- [130] LECUN, Y., HAFFNER, P., BOTTOU, L., BENGIO, Y.: *Object Recognition with Gradient-Based Learning*. In: Forsyth, D. u. Forsyth, D. A. (Hrsg.): *Shape, contour and grouping in computer vision*. Lecture Notes in Computer Science, Bd. 1681. Heidelberg: Springer

- 1999, S. 319–345. ISBN 978-3-540-66722-3. doi: 10.1007/3-540-46805-6_19
- [131] LEINWEBER, S.: *Analyse der Wechselwirkungen zwischen Streckengeometrie und Energiebedarf im Karlsruher Straenbahnnetz*, Karlsruher Institut fr Technologie, Bachelorarbeit. Karlsruhe 2020
- [132] LEIPZIGER VERKEHRSBETRIEBE (LVB) GMBH: *Advanced training for safe and economic driving of electronically powered vehicles*, 2014. https://www.eltis.org/sites/default/files/training-materials/training_borschure_tram_en-1.pdf, abgerufen: 04.02.2022
- [133] LEVINSON, J., ASKELAND, J., BECKER, J., DOLSON, J., HELD, D., KAMMEL, S., KOLTER, J. Z., LANGER, D., PINK, O., PRATT, V., SOKOLSKY, M., STANEK, G., STAVENS, D., TEICHMAN, A., WERLING, M., THRUN, S.: *Towards fully autonomous driving: Systems and algorithms*. 2011 IEEE Intelligent Vehicles Symposium (IV 2011) ; Baden-Baden, Germany, 5 - 9 June 2011. Piscataway, NJ: IEEE 2011, S. 163–168. ISBN 978-1-4577-0890-9. doi: 10.1109/IVS.2011.5940562
- [134] LI, J., CHENG, H., GUO, H., QIU, S.: *Survey on Artificial Intelligence for Vehicles*
Automotive Innovation, Bd. 1, Nr. 1, S. 2–14, 2018. ISSN 2096-4250. doi: 10.1007/s42154-018-0009-9
- [135] LILICRAP, T. P., HUNT, J. J., PRITZEL, A., HEESS, N., EREZ, T., TASSA, Y., SILVER, D., WIERSTRA, D.: *Continuous control with deep reinforcement learning*, 2015. <http://arxiv.org/pdf/1509.02971v6>, abgerufen: 15.06.2022

- [136] LIN, Y., MCPHEE, J., AZAD, N. L.: *Comparison of Deep Reinforcement Learning and Model Predictive Control for Adaptive Cruise Control*
IEEE Transactions on Intelligent Vehicles, Bd. 6, Nr. 2, S. 221–231, 2021. ISSN 2379-8904. doi: 10.1109/TIV.2020.3012947
- [137] LU, S., HILLMANSEN, S., HO, T. K., ROBERTS, C.: *Single-Train Trajectory Optimization*
IEEE Transactions on Intelligent Transportation Systems, Bd. 14, Nr. 2, S. 743–750, 2013. ISSN 1558-0016. doi: 10.1109/TITS.2012.2234118
- [138] LUNZE, J.: *Ereignisdiskrete Systeme. Modellierung und Analyse dynamischer Systeme mit Automaten, Markovketten und Petrinetzen ; mit 93 Anwendungsbeispielen und 128 Übungsaufgaben*
Oldenbourg, München, 2., überarbeitete Auflage 2012. ISBN 978-3-486-71885-0. doi: 10.1524/9783486721027
- [139] MASIKOS, M., DEMESTICHAS, K., ADAMOPOULOU, E., THEOLOGOU, M.: *Mesoscopic forecasting of vehicular consumption using neural networks*
Soft Computing, Bd. 19, Nr. 1, S. 145–156, 2015. ISSN 1432-7643. doi: 10.1007/s00500-014-1238-4
- [140] MATUTE, J. A., VACA-RECALDE, M., PEREZ, J.: *MPC-Based Speed Tracking for Automated Urban Buses Performing V2I Communications with Traffic Lights*. 2021 24th Euromicro Conference on Digital System Design. DSD 2021 : virtual conference, 1-3 September 2021 : proceedings. Piscataway, NJ: IEEE 2021, S. 396–

401. ISBN 978-1-6654-2703-6. doi:
10.1109/DSD53832.2021.00067
- [141] MCCULLOCH, W. S., PITTS, W.: *A logical calculus of the ideas immanent in nervous activity*
The Bulletin of Mathematical Biophysics, Bd. 5, Nr. 4, S. 115–133, 1943. ISSN 0007-4985. doi: 10.1007/BF02478259
- [142] MCKINSEY GLOBAL INSTITUTE: *Big data: The next frontier for innovation, competition and productivity*, 2011. https://www.mckinsey.com/~media/mckinsey/business%20functions/mckinsey%20digital/our%20insights/big%20data%20the%20next%20frontier%20for%20innovation/mgi_big_data_full_report.pdf, abgerufen: 04.02.2022
- [143] MEISHNER, F., UWE SAUER, D.: *Technical and economic comparison of different electric bus concepts based on actual demonstrations in European cities*
IET Electrical Systems in Transportation, Bd. 10, Nr. 2, S. 144–153, 2020. ISSN 2042-9738. doi: 10.1049/iet-est.2019.0014
- [144] MENG, X., WANG, H., LIN, M., ZHOU, Y.: *Deep Reinforcement Learning for Energy-efficient Train Operation of Automatic Driving*. 2020 IEEE 8th International Conference on Computer Science and Network Technology (ICCSNT). Piscataway, NJ: IEEE 2020, S. 123–126. ISBN 978-1-7281-8123-3. doi: 10.1109/ICCSNT50940.2020.9305007
- [145] MINISTERIUM FÜR VERKEHR BADEN-WÜRTTEMBERG: *Ziele und Maßnahmen zur Verdopplung des ÖPNV 2030. Empfehlungen der ÖPNV Zukunftskommission Baden-Württemberg*, 2021.

- https://www.baden-wuerttemberg.de/fileadmin/redaktion/m-mvi/intern/Dateien/PDF/PM_Anhang/210128_ANALAGE2_PM_%C3%96PNV-Zukunftskommission_Ziel_und_Ma%C3%9Fnahmenempfehlungen_der_%C3%96PNV-Zukunftskommission.pdf, abgerufen: 04.02.2022
- [146] MIRI, I., FOTOUHI, A., EWIN, N.: *Electric vehicle energy consumption modelling and estimation—A case study*
International Journal of Energy Research, Bd. 45, Nr. 1, S. 501–520, 2021. ISSN 0363-907X. doi: 10.1002/er.5700
- [147] MIUCIC, R.: *Connected Vehicles*
Springer International Publishing, Cham 2019. ISBN 978-3-319-94784-6. doi: 10.1007/978-3-319-94785-3
- [148] MNIH, V., KAVUKCUOGLU, K., SILVER, D., RUSU, A. A., VENESS, J., BELLEMARE, M. G., GRAVES, A., RIEDMILLER, M., FIDJELAND, A. K., OSTROVSKI, G., PETERSEN, S., BEATTIE, C., SADIK, A., ANTONOGLU, I., KING, H., KUMARAN, D., WIERSTRA, D., LEGG, S., HASSABIS, D.: *Human-level control through deep reinforcement learning*
Nature, Bd. 518, Nr. 7540, S. 529–533, 2015. doi: 10.1038/nature14236
- [149] MRK MANAGEMENT CONSULTANTS GMBH: *Fahr umweltbewusst! Energieverbrauch im Schienenverkehr durch den Einsatz von Fahrerassistenzsystemen reduzieren. Marktüberblick Fahrerassistenzsysteme*, 2017. <https://www.dbu.de/media/230118011248ocd6.pdf>, abgerufen: 04.02.2022
- [150] MÜLLER, C., FISCHER, T.: *Digitalisierung im Test: Versuchszug, Teststrecke und Forschungscampus*

- Eisenbahntechnische Rundschau (ETR), Nr. 01-02, S. 15–20, 2019
- [151] MULONGO, N. Y., MNKANDLA, E., KANAKANA-KATUMBA, G.: *Artificial Intelligence as Key Driver for Competitiveness in the Railway Industry: Review*. 2021 62nd International Scientific Conference on Information Technology and Management Science of Riga Technical University (ITMS). IEEE 2021 - 2021, S. 1–6. ISBN 978-1-6654-0615-4. doi: 10.1109/ITMS52826.2021.9615314
- [152] MUTH, F.: *Automatisiertes Fahren im ÖPNV. Ein Überblick über die Erprobung bei Schnellbahn, Straßenbahn, Bus und Shuttle* Der Nahverkehr, Nr. 10, S. 27–34, 2019
- [153] NAZNIN, F., CURRIE, G., LOGAN, D.: *Key challenges in tram/streetcar driving from the tram driver's perspective – A qualitative study* Transportation Research Part F: Traffic Psychology and Behaviour, Bd. 49, S. 39–48, 2017. ISSN 1369-8478. doi: 10.1016/j.trf.2017.06.003
- [154] NIEßEN, N., SCHINDLER, C., Vallée Dirk: *Assistierter, automatischer oder autonomer Betrieb - Potentiale für den Schienenverkehr* Eisenbahntechnische Rundschau (ETR), Nr. 4, S. 32–37, 2017
- [155] NIKITAS, A., MICHALAKOPOULOU, K., NJOYA, E. T., KARAMPATZAKIS, D.: *Artificial Intelligence, Transport and the Smart City: Definitions and Dimensions of a New Mobility Era* Sustainability, Bd. 12, Nr. 7, S. 2789, 2020. doi: 10.3390/su12072789

- [156] OTTO, P.: *Untersuchung zur Auswirkung von Energiespeichern im Karlsruher Nahverkehrsnetz*, Karlsruher Institut für Technologie, Dissertation. Karlsruhe 2022
- [157] OTTO, P., TESAR, M., GRATZFELD, P.: *Design and Evaluation Examples of a Data Acquisition System for Light Rail Applications* Proceedings of the 33rd Electric Vehicle Symposium, EVS 33, Portland, USA, S. 1–6, 2020. doi: 10.5281/ZENODO.4023279
- [158] Palm, G. u. Aertsen, A. (Hrsg.): *Brain Theory* Springer Berlin Heidelberg, Heidelberg 1986
- [159] PALMER, A. W., SEMA, A., MARTENS, W., RUDOLPH, P., WAIZENEGGER, W.: *The Autonomous Siemens Tram*. 2020 IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC). Piscataway, NJ: IEEE 2020, S. 1–6. ISBN 978-1-7281-4149-7. doi: 10.1109/ITSC45102.2020.9294699
- [160] PATLINS, A., KUNICINA, N., ZHIRAVECKA, A., SHUKAEVA, S.: *LIDAR Sensing Technology Using in Transport Systems for Tram Motion Control* Elektronika ir Elektrotechnika, Bd. 101, Nr. 5, S. 13–16, 2010. ISSN 2029-5731
- [161] PINEDA-JARAMILLO, J., MARTÍNEZ-FERNÁNDEZ, P., VILLALBA-SANCHIS, I., SALVADOR-ZURIAGA, P., INSA-FRANCO, R.: *Predicting the traction power of metropolitan railway lines using different machine learning models* International Journal of Rail Transportation, Bd. 9, Nr. 5, S. 461–478, 2021. ISSN 2324-8378. doi: 10.1080/23248378.2020.1829513

- [162] PLISSONNEAU, A., TRENTESAUX, D., BEN-MESSAOUD, W., BEKRAR, A.: *AI-based speed control models for the autonomous train: a literature review*. 2021 Third International Conference on Transportation and Smart Technologies. Proceedings : TST 2021, 27-28 May 2021, Tangier, Morocco. Piscataway, NJ: IEEE 2021, S. 9–15. ISBN 978-1-6654-2903-0. doi: 10.1109/TST52996.2021.00009
- [163] PONTRYAGIN, L. S.: *Mathematical Theory of Optimal Processes* Routledge, Boca Raton, 4th ed. 2018. ISBN 978-1-351-43307-5
- [164] POSENAU, C., KÖRNER, S.: *Energiespartpotentiale bei Metrofahrzeugen* VDE/IZBE-Symposium "Elektrische Fahrzeugantriebe und -ausrüstungen", Bd. 2016
- [165] QIN, S., BADGWELL, T. A.: *A survey of industrial model predictive control technology* Control Engineering Practice, Bd. 11, Nr. 7, S. 733–764, 2003. ISSN 0967-0661. doi: 10.1016/S0967-0661(02)00186-7
- [166] QU, J., FENG, X., WANG, Q.: *Real-time trajectory planning for rail transit train considering regenerative energy*. 2014 IEEE 17th International Conference on Intelligent Transportation Systems (ITSC 2014). Qingdao, China, 8 - 11 October 2014. Piscataway, NJ: IEEE 2014, S. 2738–2742. ISBN 978-1-4799-6078-1. doi: 10.1109/ITSC.2014.6958128
- [167] QUINLAN, J. R.: *Induction of decision trees* Machine Learning, Bd. 1, Nr. 1, S. 81–106, 1986. ISSN 0885-6125. doi: 10.1007/BF00116251

- [168] REDMAN, L., FRIMAN, M., GÄRLING, T., HARTIG, T.: *Quality attributes of public transport that attract car users: A research review*
Transport Policy, Bd. 25, S. 119–127, 2013. ISSN 0967-070X.
doi: 10.1016/j.tranpol.2012.11.005
- [169] REIMANN, S., JOST, F., GRATZFELD, P.: *Multiphysics Simulation of a Battery Electric Train Operation*
Transport Research Arena 2020, TRA 2020, Book of Abstracts,
S. 1–9, 2020. doi: 10.5445/IR/1000106014
- [170] REIMANN, S., TESAR, M., GRATZFELD, P.: *Comprehensive Comparison of Multi-Physics and Deep Learning Modelling Approaches for Data-Driven Prediction of Traction Energy Demand*. 2022 IEEE Vehicle Power and Propulsion Conference (VPPC). IEEE 2022, S. 1-6. ISBN 978-1-6654-7587-7. doi: 10.1109/VPPC55846.2022.10003296
- [171] REINHARDT, W.: *Öffentlicher Personennahverkehr*
Vieweg+Teubner Verlag, Wiesbaden 2012. ISBN 978-3-8348-1268-1. doi: 10.1007/978-3-8348-8234-9
- [172] RESCH, H.: *Branchenanalyse: Zukunft des ÖPNV: Entwicklungstendenzen und Chancen*
Hans-Böckler-Stiftung, Düsseldorf 2015. ISBN 978-3-86593-210-5
- [173] RHODE, S., VAN VAERENBERGH, S., PFRIEM, M.: *Power prediction for electric vehicles using online machine learning*
Engineering Applications of Artificial Intelligence, Bd. 87, Nr. 103278, S. 1–11, 2020. ISSN 0952-1976. doi: 10.1016/j.engappai.2019.103278

- [174] RODRIGO, E., TAPIA, S., MERA, J. M., SOLER, M.: *Optimizing Electric Rail Energy Consumption Using the Lagrange Multiplier Technique*
Journal of Transportation Engineering, Bd. 139, Nr. 3, S. 321–329, 2013. ISSN 0733-947X. doi: 10.1061/(ASCE)TE.1943-5436.0000483
- [175] ROSSEL, N., SOMMER, M., SAX, E.: *Automated and networked city buses – Optimized, demand-oriented service through intelligent use of data*. In: Commercial Vehicles 2021. Truck, bus, van, trailer : 16th International Conference, September 7 - 8, 2021, Linz, Austria. VDI-Berichte, Bd. 2380. Düsseldorf: VDI Verlag 2021, S. 215–228. ISBN 978-3-181-02380-8. doi: 10.51202/9783181023808-215
- [176] RUMELHART, D. E., HINTON, G. E., WILLIAMS, R. J.: *Learning representations by back-propagating errors*
Nature, Bd. 323, Nr. 6088, S. 533–536, 1986. doi: 10.1038/323533a0
- [177] SAX, E.: *Potentiale der Automatisierung im ÖPNV. Die Innovation, die aus der Nische kommt*
Der Nahverkehr, Bd. 38, Nr. 12, S. 6–10, 2020
- [178] SAX, E., ROSSEL, N.: *Automatisierungspotentiale im ÖPNV*
V+T Verkehr und Technik, Nr. 1, S. 3–6, 2021. doi: 10.37307/j.1868-7911.2021.01.02
- [179] SCHEEPMAKER, G. M., GOVERDE, R. M., KROON, L. G.: *Review of energy-efficient train control and timetabling*
European Journal of Operational Research, Bd. 257, Nr. 2,

- S. 355–376, 2017. ISSN 0377-2217. doi:
10.1016/j.ejor.2016.09.044
- [180] SCHEEPMAKER, G. M., WILLEBOORDSE, H. Y., HOOGENRAAD, J. H., LUIJT, R. S., GOVERDE, R. M.: *Comparing train driving strategies on multiple key performance indicators*
Journal of Rail Transport Planning & Management, Bd. 13, Nr. 100163, S. 1–29, 2020. ISSN 2210-9706. doi:
10.1016/j.jrtpm.2019.100163
- [181] SCHEIBLE, D.: *Analyse von Querbeschleunigungen zur Bestimmung des Fahrkomforts auf Basis der Karlsruher Messstraßenbahn*, Karlsruher Institut für Technologie, Bachelorarbeit. Karlsruhe 2020
- [182] SCHERER, M.: *Is Light Rail More Attractive to users than bus Transit?: Arguments Based on Cognition and Rational Choice*
Transportation Research Record: Journal of the Transportation Research Board, Bd. 2144, Nr. 1, S. 11–19, 2010. ISSN 0361-1981. doi: 10.3141/2144-02
- [183] SCHERM, J.: *Klassifizierung und Analyse des Fahrverhaltens der Karlsruher Messstraßenbahn*, Karlsruher Institut für Technologie, Seminararbeit. Karlsruhe 2021
- [184] SCHNIEDER, L.: *Automatisierung Im Schienengebundenen Nahverkehr. Funktionen und Nutzen Von Communication-Based Train Control (CBTC)*
Springer Vieweg, Wiesbaden 2019. ISBN 978-3-658-25536-7
- [185] SCHRÖDER, J., GONÇALVES ALPOIM, C., Dickgießer Boris, KNOLLMANN, V.: *Digitale S-Bahn Hamburg - Erstmalige Realisierung von "ATO*

- over ETCS" in Deutschland*
SIGNAL+DRAHT, Bd. 113, Nr. 07-08, S. 52–59, 2021
- [186] SCHWEIGER, T.: *Statistische Analyse zu Verspätungen im Karlsruher Straßenbahnnetz anhand flächendeckender Langzeitmessungen*, Karlsruher Institut für Technologie, Bachelorarbeit. Karlsruhe 2020
- [187] SCHWENZER, M., AY, M., BERGS, T., ABEL, D.: *Review on model predictive control: an engineering perspective*
The International Journal of Advanced Manufacturing Technology, Bd. 117, Nr. 5-6, S. 1327–1349, 2021. ISSN 0268-3768. doi: 10.1007/s00170-021-07682-3
- [188] SHERRY, L., SHORTLE, J., DONOHUE, G., BERLIN, B., WEST, J.: *Autonomous Systems Design, Testing, and Deployment: Lessons Learned from The Deployment of an Autonomous Shuttle Bus*. 2020 Integrated Communications Navigation and Surveillance Conference (ICNS). IEEE 2020. doi: 10.1109/icns50378.2020.9222995
- [189] SICRE, C., CUCALA, A. P., FERNÁNDEZ-CARDADOR, A.: *Real time regulation of efficient driving of high speed trains based on a genetic algorithm and a fuzzy model of manual driving*
Engineering Applications of Artificial Intelligence, Bd. 29, S. 79–92, 2014. ISSN 0952-1976. doi: 10.1016/j.engappai.2013.07.015
- [190] SIEMENS MOBILITY GMBH: *Teaching trams to drive. Auf dem Weg zur smarten, autonomen Tram - ein Forschungsprojekt von Sie-*

- mens Mobility*, 2019. <https://assets.new.siemens.com/siemens/assets/api/uuid:136bd5ec-0d37-46a4-8238-0b346a7328aa/autonome-tram.pdf>, abgerufen: 04.02.2022
- [191] SINGH, P., DULEBENETS, M. A., PASHA, J., GONZALEZ, E. D. R. S., LAU, Y.-Y., KAMPMANN, R.: *Deployment of Autonomous Trains in Rail Transportation: Current Trends and Existing Challenges* IEEE Access, Bd. 9, S. 91427–91461, 2021. doi: 10.1109/ACCESS.2021.3091550
- [192] SMITH, L. N.: *A disciplined approach to neural network hyper-parameters: Part 1 -- learning rate, batch size, momentum, and weight decay* US Naval Research Laboratory Technical Report
- [193] SOMMER, M., JUNK, C., RÖSCH, T., SAX, E.: *Intelligent Control of HVAC Systems in Electric Buses*. In: Ahram, T., Taiar, R. u. Groff, F. (Hrsg.): *Human Interaction, Emerging Technologies and Future Applications IV. Proceedings of the 4th International Conference on Human Interaction and Emerging Technologies: Future Applications (IHET – AI 2021)*, April 28-30, 2021, Strasbourg, France. Springer eBook Collection, Bd. 1378. Cham: Springer International Publishing; Imprint Springer 2021, S. 68–75. ISBN 978-3-030-73270-7. doi: 10.1007/978-3-030-74009-2_9
- [194] SPRINGMANN, M.: *Auslegung eines asynchronen Langstatorlinearmotors mit großem Luftspalt als Straßenbahnantrieb* KIT Scientific Publishing, Karlsruhe 2015. ISBN 978-3-731-50418-4

- [195] STATISTA: *ÖPNV 2019. Statista Konsumentenbefragung - Tabellenband*, 2019. <https://de.statista.com/statistik/studie/id/64571/dokument/oepnv/>, abgerufen: 04.02.2022
- [196] STRAUB, T., FREY, M., GAUTERIN, F.: *Learning From the Fleet: Map Attributes for Energetic Representation of Driving Profiles* IEEE Transactions on Intelligent Transportation Systems, Bd. 23, Nr. 1, S. 471–482, 2022. ISSN 1558-0016. doi: 10.1109/TITS.2020.3011976
- [197] STRUCKL, W., RICHTER, G.: *Verbesserung der Energieeffizienz im Bereich der thermischen Komfortsysteme* Eisenbahntechnische Rundschau (ETR), Nr. 09, S. 156–160, 2014
- [198] SUN, S., ZHANG, J., BI, J., WANG, Y.: *A Machine Learning Method for Predicting Driving Range of Battery Electric Vehicles* Journal of Advanced Transportation, S. 1–14, 2019. ISSN 0197-6729. doi: 10.1155/2019/4109148
- [199] SUTTON, R. S., BARTO, A.: *Reinforcement learning. An introduction* The MIT Press, Cambridge, Massachusetts, London, England, Second edition 2018. ISBN 978-0-262-03924-6
- [200] SUWALSKI, I., WÜNSCHE, H.: *ATO over ETCS als Schlüssel für mehr Effizienz, Kapazität und Nachhaltigkeit. Erfahrungen und Strategien aus der Praxis* SIGNAL+DRAHT, Bd. 113, Nr. 9, S. 13–24, 2021
- [201] TAMMI, K., HYVARINEN, V.: *Lateral and longitudinal control of bus platoon*. 2018 IEEE International Conference on Electrical Systems for Aircraft, Railway, Ship Propulsion and Road Vehicles &

- International Transportation Electrification Conference (ESARS-ITEC). Piscataway, NJ: IEEE 2018, S. 1–6. ISBN 978-1-5386-4192-7. doi: 10.1109/ESARS-ITEC.2018.8607431
- [202] Tasler, Gerd, Knollmann, Volker: *Einführung des hochautomatisierten Fahrens - auf dem Weg zum vollautomatischen Bahnbetrieb*
SIGNAL+DRAHT, Bd. 110, Nr. 6, S. 6–14, 2018
- [203] *Technische Regeln Straßenbahn - Trassierung von Bahnen. TRStrab Trassierung*
1993
- [204] TECHNISCHE UNIVERSITÄT DARMSTADT: *Forschung für die Straßenbahn der Zukunft. Projekt MAAS untersucht Machbarkeit von Automatisierung und Teleoperation*, 2019. https://www.tu-darmstadt.de/universitaet/aktuelles_meldungen/archiv_2/2019/2019quartal2/neuesausdertueinzelansichtbreitespalte_231936.de.jsp, abgerufen: 04.02.2022
- [205] TENSORFLOW DEVELOPERS: *TensorFlow*
Zenodo 2022. doi: 10.5281/zenodo.4724125
- [206] TESAR, M.: *Predictive Maintenance - Wie mache ich meine Straßenbahn schlau?* Verband Deutscher Verkehrsunternehmen, VDV Tram-Konferenz, 2021. <https://publikationen.bibliothek.kit.edu/1000140434/134400701>, abgerufen: 12.04.2022
- [207] TESAR, M., MULLER-BROICH, S., HILMER, L., GRATZFELD, P.: *Predicting Traction Energy Demand of a Light Rail Vehicle Using Deep Learning Methods*. 2021 IEEE Vehicle Power and Propulsion

- Conference (VPPC). IEEE 2021 - 2021, S. 1–5. ISBN 978-1-6654-0528-7. doi: 10.1109/VPPC53923.2021.9699347
- [208] TESAR, M., OTTO, P., GRATZFELD, P.: *Design of a data acquisition system for condition evaluation and operation optimization of a light rail vehicle and infrastructure*
Proceedings of the 12th World Congress on Railway Research (WCRR), Tokyo, Japan, S. 1–6, 2019
- [209] TESAR, M., OTTO, P., GRATZFELD, P.: *Langzeitmessungen im Karlsruher Straßenbahnnetz*
V+T Verkehr und Technik, Nr. 11, S. 418–421, 2019. doi: 10.37307/j.1868-7911.2019.11.08
- [210] TESAR, M., OTTO, P., REIMANN, S., GRATZFELD, P.: *Konzeption und Aufbau eines modularen und passiven Messsystems zur Durchführung flächendeckender Langzeitmessungen im Karlsruher Straßenbahnnetz*
DIGITAL-RAIL 2019: BAHN-DIGITALISIERUNG Tagungsdokumentation, Nr. 71, S. 1–12, 2019
- [211] TESAR, M., OTTO, P., REIMANN, S., GRATZFELD, P.: *Karlsruher Messstraßenbahn sammelt Daten zur Optimierung von Energieeffizienz, Pünktlichkeit, Verschleiß und Komfort*
Eisenbahntechnische Rundschau (ETR), Nr. 3, S. 49–54, 2020
- [212] TESAR, M., SCHWARZ, F., GRATZFELD, P.: *Optimized Driving Profiles with Deep Reinforcement Learning for Driver Assistance Systems in Light Rail Vehicles*. 2022 IEEE 25th International Conference on Intelligent Transportation Systems (ITSC). IEEE 2022,

- S. 673–680. ISBN 978-1-6654-6880-0. doi:
10.1109/ITSC55140.2022.9922052
- [213] TESAR, M., SCHWARZ, F., GRATZFELD, P.: *Increasing Energy Efficiency and Punctuality of a Light Rail Vehicle with Deep Reinforcement Learning*
Proceedings of the 3rd International Railway Symposium (IRSA), Aachen, Germany, S. 351–366, 2021. doi:
10.18154/RWTH-2022-01715
- [214] TESAR, M., SCHWARZ, F., GRATZFELD, P.: *Steigerung von Energieeffizienz und Pünktlichkeit von Straßenbahnen durch Deep Reinforcement Learning*
Eisenbahntechnische Rundschau (ETR), Nr. 5, S. 14–17, 2022
- [215] TOPIĆ, J., ŠKUGOR, B., DEUR, J.: *Neural Network-Based Modeling of Electric Vehicle Energy Demand and All Electric Range*
Energies, Bd. 12, Nr. 1396, S. 1–20, 2019. doi:
10.3390/en12071396
- [216] TRENTESAUX, D., DAHYOT, R., OUEDRAOGO, A., ARENAS, D., LEFEBVRE, S., SCHON, W., LUSSIER, B., CHERITEL, H.: *The Autonomous Train*.
2018 13th System of Systems Engineering Conference (SoSE).
June 19–22, 2018, Sorbonne université, campus Pierre et Marie Curie, Paris, France. Piscataway, NJ: IEEE 2018, S. 514–520.
ISBN 978-1-5386-4876-6. doi: 10.1109/SYSOSE.2018.8428771
- [217] TUNG, A. K. H.: *Rule-based Classification*. In: LIU, L. u. ÖZSU, M. T. (Hrsg.): *Encyclopedia of database systems*. Springer reference.
New York, NY: Springer 2009, S. 2459–2462. ISBN 978-0-387-35544-3. doi: 10.1007/978-0-387-39940-9_559

- [218] TZOURAS, P. G., FARAH, H., PAPADIMITRIOU, E., VAN OORT, N., HAGENZIEKER, M.: *Tram drivers' perceived safety and driving stress evaluation. A stated preference experiment*
Transportation Research Interdisciplinary Perspectives, Bd. 7, Nr. 100205, S. 1–11, 2020. ISSN 2590-1982. doi: 10.1016/j.trip.2020.100205
- [219] UIC RAIL SYSTEM DEPARTMENT: *Artificial intelligence. Case of the railway sector - State of play and perspectives*, 2021.
https://uic.org/IMG/pdf/artificial_intelligence_case_of_the_railway_sector_state_of_play_and_perspectives.pdf, abgerufen: 04.02.2022
- [220] UITP: *World Report on Metro Automation*, 2018.
https://cms.uitp.org/wp/wp-content/uploads/2020/06/Statistics-Brief-Metro-automation_final_web03.pdf, abgerufen: 04.02.2022
- [221] UMWELTBUNDESAMT: *Luftreinhaltung in der EU*, 2019.
<https://www.umweltbundesamt.de/themen/luft/regelungen-strategien/luftreinhaltung-in-der-eu#fristverlangerung-no2-stand-oktober-2014>, abgerufen: 04.02.2022
- [222] UMWELTBUNDESAMT: *Emissionen des Verkehrs*, 2021.
<https://www.umweltbundesamt.de/daten/verkehr/emissionen-des-verkehrs#pkw-fahren-heute-klima-und-umweltvertraglicher>, abgerufen: 04.02.2022

- [223] UMWELTBUNDESAMT: *Fahrleistungen, Verkehrsleistungen und "Modal Split"*, 2021. <https://www.umweltbundesamt.de/daten/verkehr/fahrleistungen-verkehrsaufwand-modal-split>, abgerufen: 04.02.2022
- [224] UNITED NATIONS FRAMEWORK CONVENTION ON CLIMATE CHANGE: *The Paris Agreement*, 2016. https://unfccc.int/sites/default/files/resource/parisagreement_publication.pdf, abgerufen: 04.02.2022
- [225] UNITED NATIONS, DEPARTMENT OF ECONOMIC AND SOCIAL AFFAIRS, POPULATION DIVISION: *World Urbanization Prospects: The 2018 Revision*, 2019. <https://population.un.org/wup/Publications/Files/WUP2018-Report.pdf>, abgerufen: 04.02.2022
- [226] URBANEK, A.: *Potential of modal shift from private cars to public transport: A survey on the commuters' attitudes and willingness to switch – A case study of Silesia Province, Poland* Research in Transportation Economics, Bd. 85, Nr. 101008, S. 1–12, 2021. ISSN 0739-8859. doi: 10.1016/j.retrec.2020.101008
- [227] VAN DEN BOGAARD, P.: *How ADAS can make light rail safer and greener*, 2019. <https://www.railtech.com/rolling-stock/2019/10/28/how-ad-as-can-make-light-rail-safer-and-greener/?gdpr=deny>, abgerufen: 04.02.2022
- [228] VAN DER MALSBURG, C.: *Frank Rosenblatt: Principles of Neurodynamics: Perceptrons and the Theory of Brain Mechanisms*. In:

- Palm, G. u. Aertsen, A. (Hrsg.): *Brain Theory*. Heidelberg: Springer Berlin Heidelberg 1986, S. 245–248. ISBN 978-3-642-70913-5. doi: 10.1007/978-3-642-70911-1_20
- [229] VAN HASSELT, H., GUEZ, A., SILVER, D.: *Deep Reinforcement Learning with Double Q-Learning*
Proceedings of the AAAI Conference on Artificial Intelligence, Bd. 30, Nr. 1, 2016. ISSN 2159-5399. doi: 10.1609/aaai.v30i1.10295
- [230] VAN HOUDT, G., MOSQUERA, C., NÁPOLES, G.: *A review on the long short-term memory model*
Artificial Intelligence Review, Bd. 53, Nr. 8, S. 5929–5955, 2020. ISSN 0269-2821. doi: 10.1007/s10462-020-09838-1
- [231] VAN LIEROP, D., BADAMI, M. G., EL-GENEIDY, A. M.: *What influences satisfaction and loyalty in public transport? A review of the literature*
Transport Reviews, Bd. 38, Nr. 1, S. 52–72, 2018. ISSN 0144-1647. doi: 10.1080/01441647.2017.1298683
- [232] VERBAND DEUTSCHER VERKEHRSUNTERNEHMEN E.V.: *Kostendeckungsgrad*, 2018. <https://www.mobi-wissen.de/Finanzierung/Kostendeckungsgrad>, abgerufen: 04.02.2022
- [233] VERBAND DEUTSCHER VERKEHRSUNTERNEHMEN E.V.: *VDV-Statistik 2019*, 2020. <https://www.vdv.de/statistik-jahresbericht.aspx>, abgerufen: 04.02.2022

- [234] VERKEHRSBETRIEBE KARLSRUHE GMBH: *Citylink. Die Niederflur-Stadtbahn für Karlsruhe*, 2014. https://www.avg.info/fileadmin/user_upload/vbk/Dateien/Service/VBK_Broschuere_Citylink.pdf, abgerufen: 12.04.2022
- [235] VERKEHRSGESELLSCHAFT FRANKFURT AM MAIN MBH: *Weltweit erstes Fahrerassistenzsystem im Straßenbahn-Betrieb. Mehr Sicherheit im Straßenverkehr*, 2015. <https://www.vgf-ffm.de/de/aktuell-presse/news/einzelsicht/weltweit-erstes-fahrerassistenzsystem-im-strassenbahn-betrieb/>, abgerufen: 04.02.2022
- [236] W. Carvajal Carreño: *Efficient driving of CBTC ATO operated trains*, Delft University of Technology, Dissertation. Delft 2017. doi: 10.4233/uuid:9c1f1489-84fc-47cf-b889-ddbe3b87862f
- [237] WANG, C., LIU, W., TIAN, Q., SU, S., ZHANG, M.: *An Energy-Efficient Train Control Approach Based on Deep Q-Network Methodology*. 2020 IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC). Piscataway, NJ: IEEE 2020, S. 1–6. ISBN 978-1-7281-4149-7. doi: 10.1109/ITSC45102.2020.9294245
- [238] WANG, G., ZENG, X., BIAN, D., WANG, W.: *Research on Modern Tram Auxiliary Safety Protection Technology Based on Obstacles Detection*. In: Zeng, X., Xie, X., Sun, J., Ma, L. u. Chen, Y. (Hrsg.): *International Symposium for Intelligent Transportation and Smart City (ITASC) 2017 Proceedings*. Branch of ISADS (The International Symposium on Autonomous Decentralized Systems).

- Smart Innovation, Systems and Technologies Ser, v.62. Singapore: Springer Singapore 2017, S. 37–50. ISBN 978-981-10-3574-6. doi: 10.1007/978-981-10-3575-3_5
- [239] WANG, P., GOVERDE, R. M. P., MA, L.: *A Multiple-Phase Train Trajectory Optimization Method under Real-Time Rail Traffic Management*. 2015 IEEE 18th International Conference on Intelligent Transportation Systems (ITSC). 15 - 18 Sept. 2015, Las Palmas, Gran Canaria, Spain. Piscataway, NJ: IEEE 2015, S. 771–776. ISBN 978-1-4673-6596-3. doi: 10.1109/ITSC.2015.130
- [240] WANG, Y., SCHUTTER, B. de, VAN DEN BOOM, T. J., NING, B.: *Optimal trajectory planning for trains – A pseudospectral method and a mixed integer linear programming approach*. Transportation Research Part C: Emerging Technologies, Bd. 29, S. 97–114, 2013. ISSN 0968-090X. doi: 10.1016/j.trc.2013.01.007
- [241] WANG, Y., SCHUTTER, B. de, VAN DEN BOOM, T. J., NING, B.: *Optimal trajectory planning for trains under fixed and moving signaling systems using mixed integer linear programming*. Control Engineering Practice, Bd. 22, S. 44–56, 2014. ISSN 0967-0661. doi: 10.1016/j.conengprac.2013.09.011
- [242] WANG, Y., ZHANG, M., MA, J., ZHOU, X.: *Survey on Driverless Train Operation for Urban Rail Transit Systems*. Urban Rail Transit, Bd. 2, Nr. 3-4, S. 106–113, 2016. ISSN 2199-6687. doi: 10.1007/s40864-016-0047-8
- [243] WEBB, G. I., FÜRNKRANZ, J., HINTON, G., SAMMUT, C., SANDER, J., VLACHOS, M., TEH, Y. W., YANG, Y., MLADENI, D., BRANK, J., GROBELNIK, M.,

- ZHAO, Y., KARYPIS, G., CRAW, S., PUTERMAN, M. L., PATRICK, J.: *Decision Tree*. In: Sammut, C. u. Webb, G. I. (Hrsg.): *Encyclopedia of Machine Learning*. SpringerLink Bücher. Boston, MA: Springer US 2010, S. 263–267. ISBN 978-0-387-30768-8. doi: 10.1007/978-0-387-30164-8_204
- [244] WECKMÜLLER, B.: *Anforderungen an Unternehmen des öffentlichen Personennahverkehrs*, Karlsruher Institut für Technologie, Seminararbeit. Karlsruhe 2021
- [245] WENDE, D.: *Fahrdynamik des Schienenverkehrs* Vieweg+Teubner Verlag, Wiesbaden 2003. ISBN 978-3-322-82961-0. doi: 10.1007/978-3-322-82961-0
- [246] WERBOS, P.: *Beyond regression. New Tools for Prediction and Analysis in the Behavioral Sciences*, Harvard University, Dissertation. Cambridge, Massachusetts 1974
- [247] YIN, J., TANG, T., YANG, L., XUN, J., HUANG, Y., GAO, Z.: *Research and development of automatic train operation for railway transportation systems: A survey* Transportation Research Part C: Emerging Technologies, Bd. 85, S. 548–572, 2017. ISSN 0968-090X. doi: 10.1016/j.trc.2017.09.009
- [248] YU, T., ZHU, H.: *Hyper-Parameter Optimization: A Review of Algorithms and Applications*, 2020. <https://arxiv.org/pdf/2003.05689>
- [249] YUAN, X., ZHANG, Q., ZHANG, S., HUANG, R., ZHANG, X., YUNQIN, H.: *Longitudinal control of Autonomous-rail Rapid Tram in platooning using Model Predictive Control*. 2020 IEEE Vehicle Power and

- Propulsion Conference (VPPC). Proceedings : 18 November-16 December 2020, virtual conference. Piscataway, NJ: IEEE 2020, S. 1–5. ISBN 978-1-7281-8959-8. doi: 10.1109/VPPC49601.2020.9330878
- [250] YUSOF, N. K., ABAS, P. E., MAHLIA, T. M. I., HANNAN, M. A.: *Techno-Economic Analysis and Environmental Impact of Electric Buses* World Electric Vehicle Journal, Bd. 12, Nr. 31, S. 1–23, 2021. doi: 10.3390/wevj12010031
- [251] ZASIADKO, M.: *Bombardier to supply 30 innovative trams to Dresden*, 2019. <https://www.railtech.com/rolling-stock/2019/08/23/bombardier-to-supply-30-innovative-trams-to-dresden/>, abgerufen: 04.02.2022
- [252] ZHANG, C., WANG, M., DONG, J., LU, W., LIU, Y., NI, A., YU, X.: *Factors and Mechanism Affecting the Attractiveness of Public Transport: Macroscopic and Microscopic Perspectives* Journal of Advanced Transportation, S. 1–16, 2022. ISSN 0197-6729. doi: 10.1155/2022/5048678
- [253] ZHU, Q., SU, S., TANG, T., XIAO, X.: *Energy-efficient train control method based on soft actor-critic algorithm*. 2021 IEEE International Intelligent Transportation Systems Conference (ITSC). IEEE 2021 - 2021, S. 2423–2428. ISBN 978-1-7281-9142-3. doi: 10.1109/ITSC48978.2021.9564449
- [254] ZHU, Z., LIN, K., JAIN, A. K., ZHOU, J.: *Transfer Learning in Deep Reinforcement Learning: A Survey*, 2020. <https://arxiv.org/pdf/2009.07888>

E Auflistung eigener Veröffentlichungen

Publikationen

2023

- [E1] REIMANN, S., TESAR, M., GRATZFELD, P.: *Comprehensive Comparison of Multi-Physics and Deep Learning Modelling Approaches for Data-Driven Prediction of Traction Energy Demand*. 2022 IEEE Vehicle Power and Propulsion Conference (VPPC). IEEE 2022, S. 1-6. ISBN 978-1-6654-7587-7. doi: 10.1109/VPPC55846.2022.10003296

2022

- [E2] TESAR, M., SCHWARZ, F., GRATZFELD, P.: *Optimized Driving Profiles with Deep Reinforcement Learning for Driver Assistance Systems in Light Rail Vehicles*. 2022 IEEE 25th International Conference on Intelligent Transportation Systems (ITSC). IEEE 2022, S. 673–680. ISBN 978-1-6654-6880-0. doi: 10.1109/ITSC55140.2022.9922052
- [E3] TESAR, M., SCHWARZ, F., GRATZFELD, P.: *Steigerung von Energieeffizienz und Pünktlichkeit von Straßenbahnen durch Deep Reinforcement Learning*. Eisenbahntechnische Rundschau (ETR), Nr. 5, S. 14–17, 2022
- [E4] HECKELE, L., TESAR, M., IGELSPACHER, J., BRUNNER, J., GRATZFELD, P.: *Steigerung der Leistungsdichte und des Wirkungsgrades von Straßenbahnantrieben durch den Einsatz hochdrehender Maschinen*

e & i Elektrotechnik und Informationstechnik, Bd. 139, Nr. 2,
S. 186–194, 2022. ISSN 0932-383X.
doi: 10.1007/s00502-022-01011-6

2021

- [E5] TESAR, M.: *Predictive Maintenance - Wie mache ich meine Straßenbahn schlau?* Verband Deutscher Verkehrsunternehmen, VDV Tram-Konferenz Düsseldorf (23.-24.11.), 2021. <https://publikationen.bibliothek.kit.edu/1000140434/134400701>, abgerufen: 12.04.2022, doi: 10.5445/IR/1000140434
- [E6] TESAR, M., SCHWARZ, F., GRATZFELD, P.: *Increasing Energy Efficiency and Punctuality of a Light Rail Vehicle with Deep Reinforcement Learning* Proceedings of the 3rd International Railway Symposium (IRSA), Aachen, Germany, S. 351–366, 2021. doi: 10.18154/RWTH-2022-01715
- [E7] TESAR, M., MULLER-BROICH, S., HILMER, L., GRATZFELD, P.: *Predicting Traction Energy Demand of a Light Rail Vehicle Using Deep Learning Methods*. 2021 IEEE Vehicle Power and Propulsion Conference (VPPC). IEEE 2021 - 2021, S. 1–5. ISBN 978-1-6654-0528-7. doi: 10.1109/VPPC53923.2021.9699347

2020

- [E8] OTTO, P., TESAR, M., GRATZFELD, P.: *Design and Evaluation Examples of a Data Acquisition System for Light Rail Applications* Proceedings of the 33rd Electric Vehicle Symposium, EVS

33, Portland, USA, S. 1–6, 2020. doi: 10.5281/ZENODO.4023279

- [E9] TESAR, M., BERTHOLD, K., GRUHLER, J.-P., GRATZFELD, P.: *Design Methodology for the Electrification of Urban Bus Lines with Battery Electric Buses*
Transportation Research Procedia, Bd. 48, S. 2038–2055, 2020. ISSN 2352-1465. doi: 10.1016/j.trpro.2020.08.264
- [E10] HECKELE, L., TESAR, M., GRATZFELD, P.: *Wirkungsgradsteigerung von elektrischen Antriebssträngen mit hochdrehenden Maschinen*
Elektrische Bahnen (eb), Bd. 118, Nr. 7-8, S. 282–289, 2020
- [E11] TESAR, M., OTTO, P., REIMANN, S., GRATZFELD, P.: *Karlsruher Messstraßenbahn sammelt Daten zur Optimierung von Energieeffizienz, Pünktlichkeit, Verschleiß und Komfort*
Eisenbahntechnische Rundschau (ETR), Nr. 3, S. 49–54, 2020

2019

- [E12] TESAR, M., OTTO, P., GRATZFELD, P.: *Design of a data acquisition system for condition evaluation and operation optimization of a light rail vehicle and infrastructure*
Proceedings of the 12th World Congress on Railway Research (WCRR), Tokyo, Japan, S. 1–6, 2019
- [E13] TESAR, M., OTTO, P., REIMANN, S., GRATZFELD, P.: *Konzeption und Aufbau eines modularen und passiven Messsystems zur Durchführung flächendeckender Langzeitmessungen im Karlsruher Straßennetz*
DIGITAL-RAIL 2019: BAHN-DIGITALISIERUNG Tagungsdokumentation, Nr. 71, S. 1–12, 2019

- [E14] TESAR, M., OTTO, P., GRATZFELD, P.: *Langzeitmessungen im Karlsruher Straßenbahnnetz*
V+T Verkehr und Technik, Nr. 11, S. 418–421, 2019. doi:
10.37307/j.1868-7911.2019.11.08
- [E15] TESAR, M., BERTHOLD, K., GRATZFELD, P.: *Techno-ökonomische Auslegungsmethodik zur Elektrifizierung von Buslinien*
Elektrische Bahnen (eb), Bd. 137, Nr. 7-8, S. 268–274, 2019
- [E16] TESAR, M., OTTO, P., GRATZFELD, P.: *Karlsruher Messstraßenbahn - AVG & KIT starten den Betrieb*
Ingenieur-Spiegel, Nr. 2, S. 42–44, 2019

2018

- [E17] TESAR, M.: *Auslegungsmethodik für die Elektrifizierung von Buslinien*. Life needs Power Forum, Hannover Messe, 2018.
<https://publikationen.bibliothek.kit.edu/1000083442>,
abgerufen: 17.08.2022, doi: 10.5445/IR/1000083442

Karlsruher Schriftenreihe Fahrzeugsystemtechnik FAST Institut für Fahrzeugsystemtechnik (ISSN 1869-6058)

Eine vollständige Übersicht der Bände finden Sie im Verlagsshop

- Band 76** Kai-Lukas Bauer
Echtzeit-Strategieplanung für vorausschauendes automatisiertes Fahren
ISBN 978-3-7315-0949-3
- Band 77** Thomas Schirle
Systementwurf eines elektromechanischen Fahrwerks für Megacitymobilität
ISBN 978-3-7315-0995-0
- Band 78** Dominik Dörr
Simulation of the thermoforming process of UD fiber-reinforced thermoplastic tape laminates
ISBN 978-3-7315-0998-1
- Band 79** Dominik Robert Naake
Simulation of damage mechanisms in weave reinforced materials based on multiscale modeling
ISBN 978-3-7315-1005-5
- Band 80** Martin Hohberg
Experimental investigation and process simulation of the compression molding process of Sheet Molding Compound (SMC) with local reinforcements
ISBN 978-3-7315-1007-9
- Band 81** Benedikt Fengler
Manufacturing-constrained multi-objective optimization of local patch reinforcements for discontinuous fiber reinforced composite parts
ISBN 978-3-7315-1006-2
- Band 82** Johannes Masino
Road Condition Estimation with Data Mining Methods using Vehicle Based Sensors
ISBN 978-3-7315-1004-8
- Band 83** **11. Kolloquium Mobilhydraulik**
10. September 2020, Karlsruhe
ISBN 978-3-7315-1036-9

- Band 84** Felix Weber
Beitrag zur Entwicklung von Konstantflusspumpen für Frischbeton unter genauerer Betrachtung der Dickstoffventile
ISBN 978-3-7315-1037-6
- Band 85** 8. Fachtagung
Hybride und energieeffiziente Antriebe für mobile Arbeitsmaschinen. 23. Februar 2021, Karlsruhe
ISBN 978-3-7315-1071-0
- Band 86** Sebastian Fünfgeld
Vorausschauende Regelung von Fahrzeugsystemen durch stochastische Vorhersage der Fahrzeugdynamik
ISBN 978-3-7315-1060-4
- Band 87** Isabelle Charlotte Ays
Development of a CO₂e quantification method and of solutions for reducing the greenhouse gas emissions of construction machines = Entwicklung einer CO₂e Quantifizierungsmethode und von Lösungen zur Reduzierung von Treibhausgasemissionen in Baumaschinen
ISBN 978-3-7315-1033-8
- Band 88** Alexander Bernath
Numerical prediction of curing and process-induced distortion of composite structures
ISBN 978-3-7315-1063-5
- Band 89** Nils Bulthaupt
Objektivierung des Schwingungskomforts schwerer Nutzfahrzeuge
ISBN 978-3-7315-1075-8
- Band 90** Lars Brinkschulte
Assistenzsysteme zur Reduktion des Schädigungsverhaltens von Komponenten einer mobilen Arbeitsmaschine
ISBN 978-3-7315-1089-5
- Band 91** Dominik Dörr
Adaptive Fahrhinweise für ein längsdynamisches Fahrerassistenzsystem zur Steigerung der Energieeffizienz
ISBN 978-3-7315-1090-1
- Band 92** Jürgen Römer
Steuerung und Regelung des Lenkradmoments durch Nutzung radselektiver Frontantriebe
ISBN 978-3-7315-1104-5

- Band 93** Christian Riese
Werkzeuge und Konzepte für die Untersuchung und Entwicklung zukünftiger Kfz-Bremssysteme
ISBN 978-3-7315-1125-0
- Band 94** Yaoqun Zhou
Dynamisches Bremsverhalten des Reifen-Fahrwerk-Systems
ISBN 978-3-7315-1156-4
- Band 95** Stefan Haug
Ganzheitliche Optimierung einer Axialkolbenpumpe durch bedarfsangepasste Entlastung tribologischer Kontakte
ISBN 978-3-7315-1150-2
- Band 96** Stefan Scheubner
Stochastic Range Estimation Algorithms for Electric Vehicles using Data-Driven Learning Models
ISBN 978-3-7315-1166-3
- Band 97** Yusheng Xiang
AI and IoT Meet Mobile Machines: Towards a Smart Working Site
ISBN 978-3-7315-1165-6
- Band 98** Nils Meyer
Mesoscale simulation of the mold filling process of Sheet Molding Compound
ISBN 978-3-7315-1173-1
- Band 99** Christian Timo Poppe
Process simulation of wet compression moulding for continuous fibre-reinforced polymers
ISBN 978-3-7315-1190-8
- Band 100** Torben Fischer
Modellprädiktive Regelung eines innovativen Thermomanagement-Systems für batterieelektrische Fahrzeuge
ISBN 978-3-7315-1199-1
- Band 101** Florian Wittemann
Fiber-dependent injection molding simulation of discontinuous reinforced polymers
ISBN 978-3-7315-1217-2
- Band 102** Sebastian Watzl
Experimentelle und numerische Analyse des Körperschallübertragungsverhaltens von Aggregatlagerelementen im akustisch relevanten Frequenzbereich
ISBN 978-3-7315-1226-4

- Band 103** Dominik Stretz
Vibroakustische Analyse eines elektrischen Radnabenmotors und Optimierung durch geeignete Steuerungsansätze
ISBN 978-3-7315-1245-5
- Band 104** Mohamed Elgharbawy
Measurable Safety of Automated Driving Functions in Commercial Motor Vehicles - Technological and Methodical Approaches
ISBN 978-3-7315-1254-7
- Band 105** Bernhard Schmiedel
Indirekte Schätzung des Fahrbahnneigungsgrads zur Detektion von gefährlichen Fahrzuständen
ISBN 978-3-7315-1258-5
- Band 106** 9. Fachtagung
Hybride und energieeffiziente Antriebe für mobile Arbeitsmaschinen. 28. Februar 2023, Karlsruhe
ISBN 978-3-7315-1260-8
- Band 107** Patrick Riehm
Zur Wechselwirkung zwischen Fahrbahntextur und Laufstreifenmischung von Pkw-Reifen
ISBN 978-3-7315-1268-4
- Band 108** Markus Tesar
Deep Reinforcement Learning zur Steigerung von Energieeffizienz und Pünktlichkeit von Straßenbahnen
ISBN 978-3-7315-1277-6

Eine Steigerung von Energieeffizienz und Pünktlichkeit resultiert in einer erhöhten Wirtschaftlichkeit und Leistungsfähigkeit des Bahnsystems. Im Straßenbahnbereich sind die Automatisierungsmöglichkeiten begrenzt und durch das Fahren auf Sicht sind die Fahrer von der sicheren Fahrzeugführung vereinnahmt. Fahrzeitreserven sind dagegen durch das Fahrgast- und Verkehrsaufkommen variabel. Aufgrund dieser Variabilität bietet sich der Einsatz von Künstlicher Intelligenz (KI) an, welche die Muster über den Tag erlernen kann und daraufhin angepasste Fahrprofile ermittelt.

Diese Arbeit untersucht, wie die Energieeffizienz und Pünktlichkeit von Straßenbahnen durch den Einsatz von KI gesteigert werden können. Auf zwei Szenarien wird die KI zu je drei Verkehrszeiten trainiert. Die ermittelten Fahrprofile werden mit denen von Fahrern aus dem regulären Fahrgastbetrieb sowie mit einem durch Dynamic Programming ermittelten theoretischen Optimum verglichen. Darüber hinaus werden Transferlernfähigkeiten der KI auf unbekanntem betrieblichen Szenarien und Strecken untersucht.

