Simulative Untersuchungen zu effizienter Längsdynamikregelung von Fahrzeugen im städtischen Verkehr

Autor: Tobias Eichenlaub, M.Sc.
Herausgeber: Prof. Dr.-Ing. S. Rinderknecht

TECHNISCHE UNIVERSITÄT DARMSTADT

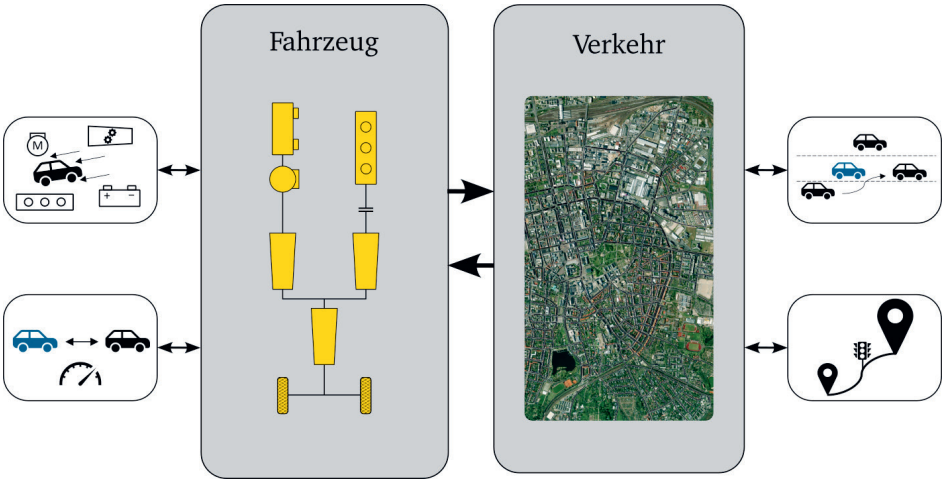

MASCHINENBAU
We engineer future
IMS

Simulative Untersuchungen zu effizienter Längsdynamikregelung von Fahrzeugen im städtischen Verkehr

Vom Fachbereich Maschinenbau

an der Technischen Universität Darmstadt

zur

Erlangung des Grades eines Doktor-Ingenieurs (Dr.-Ing.)

genehmigte

DISSERTATION

vorgelegt von

TOBIAS EICHENLAUB, M.SC.

aus Speyer

Berichterstatter:	Prof. Dr.-Ing. Stephan Rinderknecht
Mitberichterstatter:	Prof. Dr.-Ing. Steven Peters
Tag der Einreichung:	29.05.2023
Tag der mündlichen Prüfung:	19.07.2023

Darmstadt 2023

D17

MASCHINENBAU
We engineer future
IMS

Forschungsberichte Mechatronische Systeme im Maschinenbau

Tobias Eichenlaub

Simulative Untersuchungen zu effizienter Längsdynamikregelung von Fahrzeugen im städtischen Verkehr

D 17 (Diss. TU Darmstadt)

Shaker Verlag
Düren 2023

Bibliografische Information der Deutschen Nationalbibliothek
Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über http://dnb.d-nb.de abrufbar.

Zugl.: Darmstadt, Techn. Univ., Diss., 2023

Copyright Shaker Verlag 2023
Alle Rechte, auch das des auszugsweisen Nachdruckes, der auszugsweisen oder vollständigen Wiedergabe, der Speicherung in Datenverarbeitungsanlagen und der Übersetzung, vorbehalten.

Printed in Germany.

ISBN 978-3-8440-9271-4
ISSN 2198-8536

Shaker Verlag GmbH • Am Langen Graben 15a • 52353 Düren
Telefon: 02421 / 99 0 11 - 0 • Telefax: 02421 / 99 0 11 - 9
Internet: www.shaker.de • E-Mail: info@shaker.de

Kurzfassung

Im Zuge der politischen Ziele zur Reduktion der Treibhausgasemissionen im Verkehrssektor werden verschiedene Ansätze für Fahrzeugsysteme verfolgt, um den Energiebedarf der Fahrzeuge und die damit verbundenen Treibhausgasemissionen zu senken. Neben Maßnahmen wie der Elektrifizierung von Fahrzeugantrieben liegt auch in der Fahrzeugführung ein wichtiger Hebel zur Reduktion des Energiebedarfs und der Emissionen. Daher gewinnen Ansätze zur effizienten automatisierten Längsdynamikführung zunehmend an Bedeutung. Vor diesem Hintergrund wird in der vorliegenden Arbeit ein längsdynamischer Regelungsansatz entwickelt, mit dem durch die Integration von prädiktiven Elementen anhand von daten- bzw. wissensbasierten Methoden eine vorausschauende Fahrweise für den städtischen Verkehr erzielt wird.

Um die Auswirkungen auf die Energieeffizienz der Regelung modellbasiert untersuchen zu können, wird eine Co-Simulationsumgebung aus einer Fahrzeugsimulation und einer Verkehrssimulation entwickelt. Mit der Fahrzeugsimulation können Fahrzeuge mit verschiedenen Antriebsarten modelliert werden und die Auswirkungen der Längsdynamikregelung auf den Energiebedarf der Fahrzeuge abgebildet werden. Die Verkehrssimulation basiert auf einem mikroskopischen Verkehrsmodell des Stadtgebiets von Darmstadt und ermöglicht die Untersuchung bei variierenden Fahrstrecken und Verkehrsumgebungen. Für die vorausschauende Längsdynamikregelung werden Informationen einer V2X-Fahrzeugkommunikationsschnittstelle genutzt und ein neuronales Prädiktionsmodell auf Basis von Methoden des maschinellen Lernens entwickelt. Ein konventioneller längsdynamischer Regelungsansatz wird um einen Prädiktionsregelungsmodus erweitert, in dem das Modell die zukünftigen Verläufe der Geschwindigkeiten relevanter Fahrzeuge prädiziert und um so antizipierend reagieren zu können.

Die Untersuchung des Regelungsansatzes im simulativen Testbetrieb zeigt, dass durch eine Reduktion von Brems- und Beschleunigungsvorgängen eine Reduktion der Energiebedarfe von Fahrzeugen sowie eine Verringerung von kritischen Situationen der Fahrsicherheit erzielt werden, dabei jedoch die Fahrzeit in realistischen Verkehrsszenarien gegenüber der Referenzregelung erhöht wird. Gleichzeitig zeigt sich eine teils starke Abhängigkeit der vergleichenden Bewertung der Längsdynamikregelung von den Faktoren Fahrzeug, Verkehrsumfeld und Fahrstrecke und macht deutlich, dass diese Faktoren bei der modellbasierten Entwicklung berücksichtigt werden müssen.

Abstract

In the context of the political goals to reduce greenhouse gas emissions in the transportation sector, various approaches for vehicle systems are being pursued to reduce the energy demand of vehicles and the associated greenhouse gas emissions. In addition to approaches like the electrification of vehicle drives, vehicle control is also an important factor in reducing energy demand and emissions. Therefore, approaches for efficient automated longitudinal control are gaining in significance. With this in consideration, a longitudinal control approach is developed in this dissertation to achieve an efficient predictive driving style in urban traffic by integrating predictive elements using data- and knowledge-based methods.

In order to be able to investigate the effects on the energy efficiency of the control in a model-based approach, a co-simulation environment consisting of a vehicle simulation and a traffic simulation is developed. In the vehicle simulation, vehicles with different types of drives can be modelled and the effects of the longitudinal control on the energy demand of the vehicles can be depicted. The traffic simulation is based on a microscopic traffic model of the urban area of Darmstadt and allows the investigation of varying driving routes and traffic environments. For the predictive longitudinal dynamic control, information from a V2X communication interface is used and a neural prediction model based on machine learning methods is developed. A conventional longitudinal control approach is extended by a prediction control mode in which the model predicts the future course of the speeds of relevant vehicles and can thus react in an anticipatory manner.

The investigation of the control approach in simulative test scenarios shows that a reduction of braking and acceleration maneuvers leads to a reduction of the energy demand of vehicles as well as a reduction of critical situations for driving safety, but also to an increase of the trip time in realistic traffic scenarios compared to the reference control. At the same time, the comparative evaluation of the longitudinal control is in part strongly dependent on the factors vehicle, traffic environment and driving distance and outlines that these factors must be taken into account in the model-based development of longitudinal control approaches.

Inhaltsverzeichnis

Kurzfassung ..... **I**

Abstract ..... **II**

Inhaltsverzeichnis ..... **III**

Abbildungsverzeichnis ..... **VI**

Tabellenverzeichnis ..... **IX**

Symbolverzeichnis ..... **X**

1 Einleitung **1**
1.1 Motivation und Ziele 1
1.2 Aufbau der Arbeit 3

2 Stand der Technik **5**
2.1 Einflüsse auf die Energieeffizienz von Fahrzeugen 5
2.2 Einordnung längsdynamischer Regelungsansätze 7
2.3 Maschinelles Lernen in der Längsdynamikregelung 11
2.3.1 Grundlagen des Trainings künstlicher neuronaler Netze 13
2.3.2 Maschinelles Lernen für neuronale Regler 20
2.3.3 Maschinelles Lernen für Prädiktionsaufgaben 21
2.4 Anwendungen von Vehicle-2-X 22
2.5 Schlussfolgerungen für die Ausrichtung der Arbeit 25

3 Mikroskopische Verkehrsmodellierung und -simulation **29**
3.1 Einordnung von Verkehrsmodellierungsansätzen und Softwaretools 29
3.2 Verkehrssimulation Simulation of Urban Mobility 31
3.3 Mikroskopisches Verkehrsmodell der Innenstadt Darmstadt 34
3.3.1 Erstellung des Verkehrsnetzes 34
3.3.2 Modellierung der Verkehrsnachfrage 37
3.3.3 Fahrzeugfolgemodelle 42
3.3.4 Wahl und Parametrierung des Fahrzeugfolgemodells 47

4 Fahrzeugmodellierung **56**
4.1 Wahl des Detaillierungsgrads 57

4.2 Längsdynamikmodell ... 59
4.3 Generische Antriebsstrangtopologie ... 61
4.3.1 Komponentenmodelle ... 62
4.3.2 Betriebsstrategie ... 67
4.4 Ableitung von Stellvertreterfahrzeugen ... 70

5 Längsdynamischer Regelungsansatz ... 75
5.1 Zielsetzung für den Regelungsansatz ... 76
5.2 Bewertungsmetriken ... 78
5.2.1 Energiebedarf und Fahrzeit ... 79
5.2.2 Fahrsicherheit ... 80
5.3 Längsdynamischer Referenzansatz ... 83
5.4 Integration prädiktiver Elemente mit V2X ... 86
5.4.1 Annahmen für die V2X-basierten Informationen ... 86
5.4.2 Anpassung der freien Fahrt an Lichtsignalanlagen ... 87
5.4.3 Prädiktive Anpassung an das vorausfahrende Fahrzeug ... 90

6 Neuronales Prädiktionsmodell ... 94
6.1 Methodischer Ansatz ... 94
6.2 Feature engineering und Trainingsdatengewinnung ... 96
6.3 Grundlegende Netzstruktur ... 101
6.4 Trainingsprozess ... 103
6.4.1 Wahl zentraler Hyperparameter des KNN ... 107
6.4.2 Wahl einer geeigneten Teilmenge an features ... 110
6.5 Einflüsse des Prädiktionshorizonts und der V2X-Informationen ... 113

7 Untersuchungen im simulativen Testbetrieb ... 117
7.1 Rahmenbedingungen und Voruntersuchungen ... 117
7.1.1 Rahmenbedingungen des simulativen Testbetriebs ... 118
7.1.2 Nachtraining im Betrieb und Wahl des Prädiktionshorizonts ... 120
7.2 Analyse der Auswirkungen der prädiktiven Elemente ... 123
7.2.1 Allgemeine Analysen ... 123
7.2.2 Untersuchung der Einflussfaktoren ... 130
7.3 Vergleich bei kontinuierlicher Folgefahrt ... 139

8 Fazit ... 144

8.1 Zusammenfassung 144
8.2 Ausblick 146

Anhang A Referenzreglerparametrierung 148

Anhang B Ergänzende Ergebnisse 149

Studentische Arbeiten 153

Literaturverzeichnis 154

Abbildungsverzeichnis

Abbildung 2.1: Einteilung von Verfahren für die Regelung und Beispiele..... 8
Abbildung 2.2: Einteilung von Methoden des maschinellen Lernens und Beispiele aus Anwendung und Forschung im Automobilbereich..... 12
Abbildung 2.3: Aufbau einer *long short-term memory*-Zelle..... 19
Abbildung 2.4: Übersicht über die Ausrichtung der Arbeit. 28
Abbildung 3.1: Aufbau und Übersicht relevanter Programmbausteine von SUMO. 32
Abbildung 3.2: Darstellung des modellierten Bereichs der Innenstadt von Darmstadt. 35
Abbildung 3.3: Verteilung aller Lichtsignalanlagen und Geschwindigkeitsbegrenzungen innerhalb des Verkehrsnetzes..... 36
Abbildung 3.4: Höhenprofil des Verkehrsnetzes..... 37
Abbildung 3.5: Darstellung der Kreuzungen, an denen Verkehrsdaten ausgewertet werden..... 39
Abbildung 3.6: Vergleich der Summen-Verkehrsflüsse für Hauptverkehrzeit und Nebenverkehrzeit an den Kreuzungen..... 41
Abbildung 3.7: Gesamtanzahl der Fahrzeuge aus dem Verkehrsnachfragemodell über der Simulationszeit. 42
Abbildung 3.8: Darstellung der Routen, die in dem Messdatensatz für die Innenstadt Darmstadt enthalten sind. 49
Abbildung 3.9: Aggregiertes Fahrprofil der Messdaten von dem Versuchsfahrzeug VW Passat GTE. 50
Abbildung 3.10: Vergleich von Messdaten mit dem Versuchsfahrzeug Passat GTE mit simulierten Anfahrvorgängen des Modells von Krauss, IDM und EIDM. 52
Abbildung 3.11: Resultierendes Flottenfahrprofil des Verkehrs auf Basis des parametrierten Fahrzeugfolgemodells..... 55
Abbildung 4.1: Struktur des Fahrzeugmodells..... 59
Abbildung 4.2: Generische Antriebsstrangtopologie mit einer Verbrennungskraftmaschine, einer elektrischen Maschine, einer Batterie und drei Teilgetrieben. 62
Abbildung 4.3: Kennfelder der Verbrennungskraftmaschine und der

elektrischen Maschine inklusive Inverter. 64
Abbildung 5.1: Betriebsgrenzen von Längsbeschleunigung und Ruck für FSR-ACC nach ISO 15622. 78
Abbildung 5.2: Energiebedarfe der Stellvertreterfahrzeuge bei Konstantfahrt mit unterschiedlichen Geschwindigkeiten. 80
Abbildung 5.3: Struktur des Referenzansatzes. 83
Abbildung 5.4: Geschlossener Regelkreis der Fahrzeuggeschwindigkeitsregelung. 85
Abbildung 5.5: Erweiterte Struktur der Längsdynamikregelung. 92
Abbildung 5.6: Vereinfachte Prinzipdarstellung zu der Wahl der Regelungsmodi. 93
Abbildung 6.1: Wahl der Prädiktionshorizonte in der Literatur. 96
Abbildung 6.2: Verteilungsfunktionen für 80 % Trainings- und 20 % Testdaten. ... 101
Abbildung 6.3: Darstellung der LSTM-basierten *encoder-decoder*-Struktur. 103
Abbildung 6.4: Prozessablauf für das Modelltraining des Prädiktionsmodells. 106
Abbildung 6.5: Trainings- und Validierungsfehler über den Trainingsepochen für Modelle unterschiedlicher Komplexität bei 4-facher Kreuzvalidierung. 107
Abbildung 6.6: Mittlerer Validierungsfehler und Differenz zwischen mittlerem Validierungs- und Trainingsfehler in Abhängigkeit der Schichtgrößen für die Modellstrukturen M1 und M2. 109
Abbildung 6.7: Darstellung der Ergebnisse des BFE Algorithmus für das Modellparameterset M1-6s. 112
Abbildung 6.8: Vergleich der Prädiktionsfehler für verschiedene Prädiktionshorizonte. 115
Abbildung 7.1: Routen für den simulativen Testbetrieb. 118
Abbildung 7.2: Vergleich der Fehler der prädizierten Geschwindigkeiten auf Route 1 für das Ausgangsmodells und die Iterationen des Nachtrainings. 121
Abbildung 7.3: Vergleich der Bewertungsmetriken für verschiedene Prädiktionshorizonte für das ICEV. 122
Abbildung 7.4: Vergleich beispielhafter Geschwindigkeitsverläufe bei Regelung mit und ohne prädiktive Elemente. 124
Abbildung 7.5: Aggregierte Fahrprofile für die Regelung ohne und mit

prädiktiven Elementen. 125
Abbildung 7.6: Zusammenhang zwischen Beschleunigungen und dem Energiebedarf des ICEV. 126
Abbildung 7.7: Zusammenhang zwischen dem Median des Wirkungsgrads der EM und dem Energiebedarf des BEV. 127
Abbildung 7.8: Energiebedarf und mittlere Geschwindigkeit des BEV bei Regelung mit und ohne prädiktive Elemente..... 128
Abbildung 7.9: Vergleich der TIT bei Regelung mit C_p und C_{np}. 130
Abbildung 7.10: Einflüsse der einzelnen prädiktiven Elemente des Regelungsansatzes für das ICEV. 132
Abbildung 7.11: Einflüsse der Reglerverstärkung auf den Kraftstoffverbrauch und die mittlere Geschwindigkeit für das ICEV. 133
Abbildung 7.12: Einfluss des Fahrzeugs auf den Vergleich von C_p und C_{np}..... 135
Abbildung 7.13: Einfluss des Verkehrsumfelds auf den Vergleich von C_p und C_{np}..... 136
Abbildung 7.14: Einfluss der Fahrstrecke auf den Vergleich von C_p und C_{np}. 137
Abbildung 7.15: Vergleich von C_p und C_{np} für alle Fahrzeuge, Routen und Verkehrsnachfragemodelle. 138
Abbildung 7.16: Mittlere Geschwindigkeiten bei kontinuierlicher Folgefahrt. 140
Abbildung 7.17: Anteile am Gesamtenergiebedarf für das BEV auf Route 1. 141
Abbildung 7.18: Vergleich der Bewertungsmetriken für das BEV. 142

Tabellenverzeichnis

Tabelle 3.1: Parametrierung des Fahrzeugfolgemodells und Vergleich mit Voreinstellungen. 54
Tabelle 4.1: Modellparameter der Stellvertreterfahrzeuge..... 72
Tabelle 6.1: Übersicht über die in dieser Arbeit definierten *features* des Prädiktionsmodells..... 99
Tabelle 6.2: Rahmenbedingungen für das Training des Prädiktionsmodells mit einer Horizontlänge von 10 s. 108
Tabelle 6.3: Optimale Modellparameter für die verschiedenen Prädiktionshorizonte. 114
Tabelle 7.1: Vergleich der Testrouten. 119

Symbolverzeichnis

Abkürzungen

Akronym	Beschreibung
5G	Mobilfunkstandard der 5. Generation
ABS	Antiblockiersystem
ACC	Adaptive cruise control
ASR	Antriebsschlupfregelung
BEV	Batterieelektrisches Fahrzeug
BFE	Backwards feature elimination
BPTT	Backpropagation through time
CACC	Cooperative adaptive cruise control
CAN	Controller area network
C_{np}	Regelung ohne prädiktive Elemente
C_p	Regelung mit prädiktiven Elementen
ECMS	Equivalent consumption minimization strategy
EIDM	Extended intelligent driver model
EM	Elektrische Maschine
FAS	Fahrerassistenzsysteme
FFS	Forward feature selection
FSR-ACC	Full-speed-range adaptive cruise control
GLOSA	Green light optimal speed advisory
HEV	Hybridfahrzeug
HV	Hauptverkehrszeit
ICEV	Konventionelles Fahrzeug mit Verbrennungsmotor
IDM	Intelligent driver model
KNN	Künstliches neuronales Netz
LSTM	Long short-term memory
LTE	Long term evolution
MAE	Mittlerer absoluter Fehler
ML	Maschinelles Lernen
MPC	Modellprädiktive Regelung (engl. model predictive control)
MSE	Mittlerer quadratischer Fehler

NV	Nebenverkehrszeit
RL	Lernen durch Verstärkung (engl. reinforcement learning)
RNN	Rekurrente künstliche neuronale Netze
SGD	Stochastic gradient descent
SL	Überwachtes Lernen (engl. supervised learning)
SUMO	Simulation of Urban Mobility
TG	Teilgetriebe
TLS	Lichtsignalanlage (engl. traffic light system)
TraCI	Traffic communication interface
TTC	Time-to-collision
UL	Unüberwachtes Lernen (engl. unsupervised learning)
V2I	Vehicle-to-infrastructure
V2V	Vehicle-to-vehicle
V2X	Vehicle-2-X / Vehicle-to-everything
VM	Verbrennungskraftmaschine
WLAN	Wireless local area network

Lateinische Formelzeichen

Symbol	Beschreibung
a	Längsbeschleunigung
a_{RL}	Aktion bei *reinforcement learning*
$\boldsymbol{a}$	Aktivierungsvektor
A_{Fz}	Fahrzeugstirnfläche
b	Verzögerung
b_{sfc}	Spezifischer Kraftstoffverbrauch
$\boldsymbol{b}$	Bias-Vektor
c_{r}	Rollwiderstandsbeiwert
c_{w}	Luftwiderstandsbeiwert
$\boldsymbol{c}$	*Cell state* einer *long short-term memory* Zelle
C_{Fz}	Fahrzeugtyp
C_{B}	Batteriekapazität
d	Abstand zwischen Egofahrzeug und Zielfahrzeug
e	Regelabweichung

$\bar{E}^2$	Mittlerer quadratischer Fehler
f_{ReLU}	Rectified linear unit
$f_{\tanh}$	Tangens-Hyperbolicus-Funktion
f_{σ}	Sigmoid-Funktion
$\boldsymbol{f}$	*Forget gate* einer *long short-term memory* Zelle
F_{tr}	Zugkraft
g	Schaltzeiten der Grünphasen
g_{g}	Erdbeschleunigung
g_{BS}	Gewählter Gang
h	Zeitlücke
$\boldsymbol{h}$	*Hidden state* eines rekurrenten künstlichen neuronalen Netzes
H	Übertragungsfunktion
H_{u}	Unterer Heizwert
i	Übersetzung
$\boldsymbol{i}$	*Input gate* einer *long short-term memory* Zelle
I	Geschwindigkeitsintervall
j	Längsruck
J	Gütefunktional
$k_{1/2}$	Modellparameter des extended intelligent driver model
k_{br}	Faktor zur Bremsmomentenaufteilung
k_{BS}	Faktor der Drehmomentaufteilung
k_{v}	Geschwindigkeitsfaktor
K	Verstärkungsfaktor
l_{Fz}	Fahrzeuglänge
L	Fehlermetrik
m	Gesamtfahrzeugmasse
M	Gleitender Mittelwert des Moments erster Ordnung
$\widehat{M}$	Korrigierter gleitender Mittelwert des Moments erster Ordnung
n	Drehzahl
N	Anzahl
N_{pr}	Anzahl prädizierter Zeitschritte
$\boldsymbol{o}$	*Output gate* einer *long short-term memory* Zelle
p	Kleinstes Testniveau für statistische Signifikanz

P	Leistung
P_J	Kostenmatrix
Q	Quantil
Q_J	Kostenmatrix
r	Schaltzeiten der Rotphasen
r_Fz	Dynamischer Reifenradius
r_RL	Belohnung bei *reinforcement learning*
R_P	Pearson Korrelationskoeffizient
R_J	Kostenmatrix
s	Laplace-Variable
s_RL	Zustand bei *reinforcement learning*
S_b	Blinkersignal
SOC	Batterieladezustand (engl. State-of-Charge)
t	Zeit
t_M	Zeithorizont
t_pr	Prädiktionshorizont
t_rb	Rückblickhorizont
t_tc	Time-to-Collision
T	Drehmoment
TET	Time Exposed Time-to-Collision
TIT	Time Integrated Time-to-Collision
$\boldsymbol{u}_\mathrm{M}$	Stellgrößenvektor
U	Gewichtematrix (für den *hidden state*)
v	Fahrzeuggeschwindigkeit
v_0	Wunschgeschwindigkeit für freie Fahrt
$\hat{v}$	Prädizierte Geschwindigkeit
V	Gleitender Mittelwert des Moments zweiter Ordnung
$\hat{V}$	Korrigierter gleitender Mittelwert des Moments zweiter Ordnung
W	Gewichtematrix
$\boldsymbol{x}$	Eingänge einer Schicht von künstlichen neuronalen Netzen
$\boldsymbol{x}_\mathrm{M}$	Zustandsvektor
$\boldsymbol{y}$	Zielwerte der Trainingsdaten
$\hat{\boldsymbol{y}}$	Ausgaben eines künstlichen neuronalen Netzes

$\boldsymbol{z}$	Vektor der gewichteten Summe einer Netzschicht

Griechische Formelzeichen

Symbol	Beschreibung
α_s	Steigungswinkel
β	Hyperparameter des Adam-Algorithmus
γ	Lernrate
δ	Beschleunigungsexponent
Δt	Zeitschrittweite der Simulationsumgebung
ϵ	Hyperparameter des Adam-Algorithmus
ζ	Geschwindigkeitsstörung
η	Wirkungsgrad
λ	Äquivalenzkostenfaktor
μ	Erwartungswert
π	Strategie bei *reinforcement learning*
ρ	Luftdichte
σ	Standardabweichung
τ	Zeitkonstante
τ_0	Reaktionszeit des Fahrers

Subskripte

Index	Beschreibung
ac	Prädiktionsregelung
br	Bremse
B	Batterie
BS	Betriebsstrategie
d	Abstand
des	Wunsch
e	Egofahrzeug
eff	Effektiv
fc	Regelung für freie Fahrt
Fz	Fahrzeug

hc	Zeitlückenregelung
I	Integralanteil
korr	Korrigiert
KS	Kolonnenstabilität
l	Vorausfahrendes Fahrzeug / Zielfahrzeug
la	Fahrstreifen
max	Maximal
min	Minimal
off	Beginn Anfahrvorgang
p	Proportionalanteil
set	Sollwert
TG	Teilgetriebe
v	Verlust

Notation

Symbol	Bedeutung
$\{a, b, c\}$	Menge
$[a, b]$	Geschlossenes Intervall
$A\,\boldsymbol{b}$	Matrixprodukt
$A \circ B$	Hadamard-Produkt
$\boldsymbol{a}$	Vektor
$a = b = c$	Gleichungskette
$\lvert A(s)\rvert_\infty$	Betrag von A für alle Werte von s
$\boldsymbol{a}^{\mathrm{T}}$	Transponierte von $\boldsymbol{a}$
$\bar{a}$	Mittelwert von a
$\dot{x}$	Zeitliche Ableitung
$\boldsymbol{x}_{\mathrm{a/b}}$	Vektor aus den Größen x_{a} und x_{b}