Prädiktive kooperative Fahrfunktion zur energie- und verkehrseffizienten Fahrzeugführung

Xiaonan Klingbeil

Prädiktive kooperative Fahrfunktion zur energie- und verkehrseffizienten Fahrzeugführung

Predictive Cooperative Driving Function for Energy- and Traffic-efficient Vehicle Control

Von der Fakultät für Maschinenwesen der Rheinisch-Westfälischen Technischen Hochschule Aachen zur Erlangung des akademischen Grades einer

Doktorin der Ingenieurwissenschaften

genehmigte Dissertation

vorgelegt von

Xiaonan Klingbeil, geb. Zhang

Berichter: Univ.-Prof. Dr.-Ing. Jakob Lukas Andert

Univ.-Prof. Dr.-Ing. (USA) Stefan Pischinger

Datum der mündlichen Prüfung: 22. November 2024

Diese Dissertation ist auf den Internetseiten der Universitätsbibliothek online verfügbar.

谨以此献吾父，若在天之灵，见此论文得成，当欣慰而宽怀矣。

Meinem Vater, der, wie ich glaube, unendlich stolz und glücklich wäre, diese Arbeit vollendet zu sehen, wenn er noch bei uns sein könnte.

Vorwort

Diese Dissertationsschrift entstand im Rahmen meiner wissenschaftlichen Tätigkeit am Lehr- und Forschungsgebiet Mechatronik in mobilen Antrieben der RWTH Aachen University. Mein besonderer Dank gilt all jenen, die mit ihrer Unterstützung zum Gelingen dieser Arbeit beigetragen haben. Insbesondere danke ich meinem Doktorvater, Herrn Univ.-Prof. Dr.-Ing. Jakob Andert, für seine kontinuierliche Unterstützung und wertvolle wissenschaftliche Begleitung während der gesamten Promotionszeit. Ebenso möchte ich Herrn Univ.-Prof. Dr.-Ing. (USA) Stefan Pischinger meinen herzlichen Dank für die Übernahme des Korreferats aussprechen. Weiteren Dank richte ich an Herrn Univ.-Prof. Alexander Mitsos, Ph.D., für den Vorsitz der Prüfungskommission sowie an Herrn Univ.-Prof. Isaac Boxx, Ph.D., für den Beisitz.

Mein besonderer Dank gilt Herrn Dr.-Ing. Thorsten Plum, Herrn Dr.-Ing. Marius Wegener und Herrn Dr.-Ing. Markus Eisenbarth für die intensiven Diskussionen im Rahmen der Themenfindung, die maßgeblich zum Erfolg dieser Dissertation beigetragen haben. Herrn Dr.-Ing. Marius Wegener danke ich für die Bereitstellung des Prädiktionsmodells sowie Herrn Lucas Koch und Herrn Kevin Badalian für die Bereitstellung des Fahrzeugmodells. Ferner möchte ich meinen Studenten Haibo Zhou, Joshua Valter, David Franzmann, Xueying Yang, Julius Weltin, Shichao Xu, Sahithi Gottumukula, Tianqi Li, Fabian Leeners und Pascal Rodewald meinen Dank aussprechen, deren vorbereitende und unterstützende Arbeiten wesentlich zum Gelingen dieser Dissertation beigetragen haben.

Im Rahmen der Forschungsprojekte Hy-Nets und Hy-Nets4all, die durch den Europäischen Fonds für Regionale Entwicklung (EFRE) sowie das Land Nordrhein-Westfalen gefördert wurden, wurden die vorliegenden Ergebnisse erzielt. Mein besonderer Dank gilt sämtlichen Projektpartnern, insbesondere der dSPACE GmbH, die durch die Bereitstellung von Softwarelizenzen und Hardware maßgeblich zum Erfolg beigetragen hat, sowie den Kollegen der Universität Paderborn, die mir ihr Verkehrssimulationsmodell zur Verfügung gestellt haben.

Des Weiteren möchte ich mich ganz besonders bei meinen Freunden und Kollegen – insbesondere bei Martina, Alexander, Lukas, Maximilian, Michael, Thorsten, Marius, Markus, Rene, Lucas, Max, Christoph, Björn und Nicolas – herzlich bedanken. Danke für eure beständige Unterstützung und Begleitung, die mir während der gesamten Promotionszeit stets Hoffnung und Freude geschenkt und meinen Fortschritt maßgeblich vorangebracht haben. Abschließend richte ich meinen Dank an meine Eltern, meine Familie und meinen Mann Nils. Ohne eure unermüdliche Unterstützung, euer tiefes Verständnis und eure bedingungslose Liebe wäre diese Arbeit nicht möglich gewesen.

Aachen, März 2025 Xiaonan Klingbeil

Kurzfassung

Die vorliegende Dissertationsschrift konzentriert sich auf die Entwicklung und Evaluierung einer prädiktiven kooperativen Fahrfunktion, die sowohl eine optimierungsbasierte Fahrzeugführung als auch ein ganzheitliches Fahrmanövermanagement berücksichtigt. In realistischen Verkehrssimulationen wird die prädiktive kooperative Fahrfunktion auf ihr Energieeinsparungspotenzial und die Fähigkeit zur Verbesserung des Verkehrsflusses untersucht. Zu Beginn werden in einer umfangreichen Simulationsumgebung, basierend auf dem inneren Ring der Paderborner Innenstadt, realitätsnahe Verkehrsszenarien generiert. Diese Umgebung ermöglicht eine realistische Abbildung von Routenführung, Schaltprogrammen und Verkehrsaufkommen. Durch die Anpassung des IDM-Fahrzeugfolgemodells mittels realer Messdaten wird ein realistisches Fahrverhalten der Verkehrsteilnehmer modelliert. Die Parametrierung des Simulationsszenarios wird anhand der Verkehrskenngrößen verifiziert, sodass die Bewertung der Fahrstrategie unter realistischen Bedingungen erfolgen kann. Zwei LSTM-Netzwerke prädizieren die longitudinale Geschwindigkeit des vorausliegenden Fahrzeugs sowie die longitudinale und laterale Geschwindigkeit benachbarter Verkehrsteilnehmer, insbesondere während eines Fahrstreifenwechsels. Die Prädiktionsgenauigkeit dieser Modelle wird validiert und zeigt insgesamt zuverlässige Ergebnisse mit geringen Abweichungen. Ein zentralisierter Ansatz wird sowohl für die optimierungsbasierte Fahrzeugführung als auch für das Fahrmanövermanagement konzipiert, in dem die Fahrzeugzustände sowohl des Kolonnenführers als auch aller Folgefahrzeuge gemeinsam in einem auf einem modellprädiktiven Regelungsalgorithmus basierenden Optimierungsproblem betrachtet werden. Die entwickelte Fahrfunktion erlaubt eine energetisch optimierte Geschwindigkeitsanpassung, sowohl bei Folgefahrt als auch bei unterschiedlichen Fahrmanövern. Bei mikroskopischer Analyse der Simulationsergebnisse werden abhängig vom Verkehrsaufkommen unterschiedliche Energieeinsparpotenziale ermittelt. Im Bereich freier Verkehrsszenarien zeigt sich, dass das Modell zwar den Abstand zwischen den Kolonnenfahrzeugen verringert, es jedoch in einigen Fällen zu Verzögerungen und nachteiligen Auswirkungen für benachbarte Verkehrsteilnehmer führen kann. Somit beträgt das gesamte Energieeinsparpotenzial aller Kolonnenfahrzeuge 2,92 % und die Reduktion der durchschnittlichen Geschwindigkeit liegt bei 8,68 %. Bei gebundenem und gestautem Verkehr führt die ganzheitliche Koordination durch die Fahrfunktion zu effizienteren Fahrmanövern und einem verbesserten Verkehrsfluss. Das Energieeinsparpotenzial liegt zwischen 7,89 % und 9,14 % bei einer Erhöhung der durchschnittlichen Geschwindigkeit zwischen 3,66 % und 12,06 %. Makroskopisch kann festgestellt werden, dass die entwickelte Funktion für alle in der Simulation befundenen Fahrzeuge Energieeinsparungen von 0,58 % bzw. 1,62 % bei freiem und gebundenem Verkehr ermöglicht. Bei gestautem Verkehr wird eine marginale Energiebedarfssteigerung von 0,34 % festgestellt. In Korrelation dazu wird eine Erhöhung der durchschnittlichen Geschwindigkeit in allen Verkehrsszenarien von 0,47 %, 1,91 % sowie 2,94 % erreicht. Darüber hinaus bestätigen Fundamentaldiagramme die Vorteile der vorausschauenden und optimierungsbasierten Geschwindigkeitsregelung, wodurch eine bessere Anpassung der Geschwindigkeit an dynamische Verkehrsbedingungen ermöglicht und zu einer Stabilisierung des Verkehrsflusses beigetragen wird.

Abstract

The present dissertation focuses on the development and evaluation of a predictive cooperative driving function, which includes both optimization-based vehicle control and a holistic driving maneuver management. Using realistic traffic simulations, the predictive cooperative driving function is assessed for its potential energy savings and its capability to optimize traffic flow. Initially, a comprehensive simulation environment is established, based on the inner ring of Paderborn's city center, to generate realistic traffic scenarios. This environment enables an accurate modeling of route planning, traffic light switching programs, and traffic volume. By adjusting the intelligent driver model using real measurement data, the realistic driving behavior of traffic participants is simulated. The parameterization of the simulation scenario is validated based on traffic metrics, ensuring the assessment of the driving strategy under realistic conditions. Two LSTM networks predict the longitudinal velocity of the preceding vehicle and the longitudinal and lateral velocities of neighboring vehicles, especially during a lane change maneuver. The accuracy of these models was validated and overall showed reliable results with minor deviations. A centralized approach is devised for both optimization-based vehicle control and maneuver management. In this approach, the vehicle states of the platoon leader and all following vehicles are simultaneously considered in an optimization problem based on the model predictive control algorithm. The developed driving function allows for an energy-optimized velocity adjustment in both following driving and during various maneuvers. In a microscopic analysis of the simulation scenarios, varying energy-saving potentials are identified based on traffic volume. In uncongested traffic scenarios, it is evident that while the model reduces the distance between vehicles, it occasionally leads to delays and adverse effects for neighboring traffic participants. Hence, the total energy-saving potential of all platoon vehicles is 2.92 %, and the reduction in average velocity is 8.68 %. In congested traffic, the comprehensive coordination of the driving function results in more efficient maneuvers and improved traffic flow. The energy-saving potential ranges between 7.89 % and 9.14 %, and the increase in average velocity is between 3.66 % and 12.06 %. On a macroscopic level, it was determined that the developed function enables energy savings of 0.58 % and 1.62 % for all vehicles in simulations during free-driving and steady traffic conditions. In congested traffic, a marginal increase in energy demand of 0,34 % is observed. In correlation, an increase in the average velocity across all traffic scenarios of 0.47 %, 1.91 %, and 2.94 % is achieved. Furthermore, fundamental diagrams confirm the advantages of the anticipatory and optimization-based velocity control, which offers better adaptation of the velocity to dynamic traffic conditions and contributes to stabilizing the traffic flow.

Inhaltsverzeichnis

Abbildungsverzeichnis xiv

Tabellenverzeichnis xvii

Symbolverzeichnis xix

Abkürzungsverzeichnis xxix

1 Einleitung 1

1.1 Hintergrund und Motivation automatisierter und vernetzter Fahrzeugführung 1

1.2 Zielsetzung und Vorgehensweise 2

2 Grundlagen vernetzter und automatisierter Fahrzeugführung 4

2.1 Umgebungserfassung 5

2.2 Trajektorienprädiktion der umgebenden Fahrzeugen 6

2.3 Optimierung der longitudinalen Fahrzeugführung 8

2.3.1 Kooperative Fahrfunktionen 9

2.3.2 Kooperatives Fahrmanövermanagement 11

3 Konzeption der Co-Simulationsplattform 13

4 Simulationsumgebung 15

4.1 Grundlagen zur Straßenverkehrssimulation 15

4.1.1 Grundstruktur einer Verkehrssimulation 15

4.1.2 Kenngrößen des Verkehrs 16

4.2 Modellierung des Verkehrssystems zur Untersuchung der kooperativen Fahrfunktionen 18

4.2.1 Netzmodell 19

4.2.2 Verhaltensmodell 20

4.2.3 Verkehrsnachfragemodell 22

4.3 Fahrzeugsimulation 23

4.4 Verifizierung der Simulationsumgebung 25

5 Trajektorienprädiktion umgebender Verkehrsteilnehmer 29

5.1 Grundlagen des maschinellen Lernens 29

5.1.1 Rekurrente neuronale Netzwerke 30

5.1.2 Trainingsprozess 32

5.2 Datengenerierung und -verarbeitung 33

5.2.1 Vorgehen zur Datengenerierung 33

5.2.2 Erzeugung der Trainingsdatensätze 37

5.3 Entwicklung des Prädiktionsmodells . . . 38
5.3.1 Formulierung der Netztopologien . . . 38
5.3.2 Auswahl der Hyperparameter . . . 39
5.3.3 Integration und Bewertung der trainierten Prädiktionsmodelle . . . 40

6 Prädiktive kooperative Fahrfunktion 47
6.1 Grundlagen der modellprädiktiven Regelung . . . 47
6.2 Zentralisierte kooperative Fahrfunktion für die Folgefahrt . . . 48
6.2.1 Fahrzeuglängsdynamik . . . 49
6.2.2 Kostenfunktion . . . 50
6.2.3 Nebenbedingungen . . . 51
6.2.4 Prädiktionshorizont . . . 53
6.2.5 Energieeinsparpotenzial im Folgefahrtszenario . . . 53
6.3 Kooperatives Fahrmanövermanagement . . . 58
6.3.1 Aufschließen . . . 59
6.3.2 Einscheren . . . 62
6.3.3 Ausscheren . . . 67
6.3.4 Aufteilung . . . 69
6.3.5 Koordination der Fahrmanöver . . . 78

7 Auswertung der kooperativen Fahrfunktion 80
7.1 Mikroskopische Auswertung der kooperativen Fahrfunktion . . . 80
7.1.1 Auswertung des Fahrverhaltens . . . 80
7.1.2 Auswertung des Energiebedarfs . . . 83
7.2 Makroskopische Auswertung der kooperativen Fahrfunktion . . . 89
7.2.1 Auswirkung auf den Energiebedarf und die durchschnittliche Geschwindigkeit 89
7.2.2 Auswirkung auf den Verkehrsfluss . . . 90
7.2.3 Einfluss von Parametern der Kolonnenregelung . . . 92
7.3 Diskussion der Ergebnisse . . . 96

8 Zusammenfassung und Ausblick 98

Literaturverzeichnis 101

Anhang 113
A.1 Parametrierung der Simulationsumgebung . . . 114
A.1.1 Referenzmessungen und Parametrierung der IDM-Fahrermodelle . . . 114
A.1.2 Parametrierung der Fahrzeugmodelle . . . 115
A.1.3 Aufbau des elektrischen Antriebstrangs . . . 118
A.2 Grundlagen zur Trajektorienprädiktion . . . 119
A.2.1 Künstliche neuronale Netzwerke . . . 119
A.2.2 Berechnung innerhalb der LSTM-Netzstruktur . . . 120

A.2.3 Detaillierte Beschreibung des Trainingsprozesses 121
A.3 Grundlagen und Parametereinstellung der kooperativen Fahrfunktionen 122
A.3.1 Grundprinzip der modellprädiktiven Regelung 122
A.3.2 Parametereinstellung der kooperativen Fahrfunktionen 123

Abbildungsverzeichnis

2.1 Funktionsstruktur der kooperativen Fahrfunktionen nach [2] 4

3.1 Strukturbild der Fahrzeug- und Verkehrs-Co-Simulationsplattform 13

4.1 Fundamentaldiagramm nach [96], empirische Daten aus dem in 4.2 beschriebenen Simulationsszenario mit einer maximalen Anzahl von 200 Fahrzeugen 17
4.2 Auswahl der Fahrroute: Innerer Ring in der Paderborner Innenstadt 18
4.3 Darstellung des Aufbaus von den gewählten Straßennetzwerk in SUMO 19
4.4 Darstellung der Beschleunigung gegenüber der Geschwindigkeit bei Verkehrssimulationen mit unterschiedlicher Anzahl an Fahrzeugen 25
4.5 Darstellung des Folgeverhaltens mithilfe der relativen Geschwindigkeit und des Abstands bei Verkehrssimulationen mit unterschiedlicher Anzahl an Fahrzeugen 26
4.6 Darstellung des Energiebedarfs gegenüber der Durchschnittsgeschwindigkeit der Verkehrssimulation mit unterschiedlicher Anzahl an Fahrzeugen 27
4.7 Darstellung der Verkehrssimulation mit unterschiedlicher Anzahl an Fahrzeugen im Fundamentaldiagramm 28

5.1 Schematische Darstellung des internen Aufbaus eines RNN-Moduls (links) und eines LSTM-Moduls (rechts) nach [116] 30
5.2 Trainingsprozess eines neuronalen Netzes im Zusammenhang einer Prädiktion mit vektorieller Ein- und Ausgabe für einen Iterationsschritt 32
5.3 Darstellung der Eingangsdaten für das Prädiktionsmodells des Vorausfahrzeugs 34
5.4 Darstellung der Eingangsdaten für das Prädiktionsmodells während eines Fahrstreifenwechels 35
5.5 LSTM Netztopologie eines Prädiktionsmodells für das Vorausfahrzeug 38
5.6 LSTM Netztopologie eines Prädiktionsmodells für das Fahrstreifenwechsel 39
5.7 Vergleich der tatsächlichen und prädizierten Trajektorie zur Evaluierung des Prädiktionsmodells eines Vorausfahrzeugs 41
5.8 Verteilung der Prädiktionsfehler von longitudinaler Geschwindigkeit und zurückgelegter Strecke 42
5.9 Gegenüberstellung der prädizierten und tatsächlichen longitudinalen und lateralen Geschwindigkeit sowie zurückgelegten Strecke mit LSTM-Netzwerk Topologie 6 Batch Größe 2048 (long.)/1024 (lat.) vor einem Fahrstreifenwechsel 44
5.10 Prädiktionsfehler von longitudinaler Geschwindigkeit und zurückgelegter Strecke 45
5.11 Prädiktionsfehler von lateraler Geschwindigkeit und zurückgelegter Strecke 46

6.1 Schematische Darstellung der Kommunikationen bei der zentralisierten Kolonnenregelung mit einem Kolonnenführer und vier Folgefahrzeugen 48
6.2 Struktur der zentralisierten Kolonnenregelung 49

6.3 Vergleich der Beschleunigung, der Geschwindigkeit und des Abstands von Fahrzeugen mit: (a) N_p = 5 s und 15 s, (b) KF und FF4 bei N_p = 15 s 55
6.4 Vergleich der Beschleunigung, Geschwindigkeit und des Abstands von KF mit: (a) perfekter Prädiktion und dem LSTM-Modell bei N_p = 15 s, (b) Q_besch = Q_verz= 2,5 und Q_besch = Q_verz= 25 bei N_p = 15 s 56
6.5 Prädizierte und aktuelle zurückgelegte Strecke und Geschwindigkeit von VF und KF bei N_p=15 s und Q_besch=Q_verz=15 57
6.6 Durchschnittlicher Energiebedarf und durchschnittliche Verkehrsdichte bei unterschiedlichen MPR-Parametern 58
6.7 Struktur der zentralisierten Kolonnenregelung inkl. Fahrmanövermanagement 59
6.8 Schematische Darstellung eines Aufschließ-Manövers von einem AUF inklusive des Signalaustauschs 60
6.9 Auswertung der Simulationsergebnisse zwischen 590 s und 630 s für ein exemplarisches Aufschließ-Manöver von vier FF 61
6.10 Schematische Darstellung eines Einscher-Manövers von einem AUF inklusive des Signalaustauschs 63
6.11 Schematische Darstellung der Berechnung der energieoptimierten Einscherposition eines EFs in einer Kolonne mit vier Fahrzeugen 64
6.12 Auswertung der Simulationsergebnisse für ein exemplarisches Einscher-Manöver in einer Kolonne mit zwei FFs 66
6.13 Schematische Darstellung eines Ausscher-Manövers von einem ausscherenden Fahrzeug inklusive des Signalaustauschs 67
6.14 Auswertung der Simulationsergebnisse für ein beispielhaftes Ausscher-Manöver 68
6.15 Schematische Darstellung eines Aufteilungsmanövers einer Kolonne bei einer signalisierten Kreuzung inklusive des Signalaustauschs 70
6.16 Schematische Darstellung der Berechnung der Aufteilungsposition: Positionsprädiktion (links) und tatsächliche Kolonnenaufteilung (rechts) 70
6.17 Auswertung der Simulationsergebnisse für ein beispielhaftes Aufteilungsmanöver durch eine LSA 72
6.18 Auswertung der Simulationsergebnisse für ein beispielhaftes unvorhergesehenen Aufteilungsmanöver durch eine LSA 73
6.19 Schematische Darstellung des Aufteilungsmanövers einer Kolonne durch Fahrstreifenwechsel eines nicht-automatisierten Fahrzeugs 74
6.20 Auswertung der Simulationsergebnisse für ein beispielhaftes Aufteilungsmanöver durch ein NAF 76
6.21 Auswertung der Simulationsergebnisse für ein beispielhaftes Aufteilungsmanöver durch NAF ohne Fahrstreifenwechsel 77
6.22 Schematische Darstellung der Koordination aller Fahrmanöver 79

7.1 Darstellung der Histogramme der Beschleunigung in Abhängigkeit der Geschwindigkeit von allen Kolonnenfahrzeugen 81
7.2 Darstellung der Folgeverhalten mithilfe von Histogrammen der relativen Geschwindigkeit und des Abstands von allen Kolonnenfahrzeugen 82
7.3 Darstellung der Folgeverhalten mithilfe der relativen Geschwindigkeit und des Abstands von allen Kolonnenfahrzeugen 85
7.4 Darstellung der Häufigkeit von durchgeführten Fahrmanövern in sämtlichen Simulationsszenarien 86
7.5 Darstellung des Energiebedarfs und der durchschnittlichen Geschwindigkeit aller Fahrzeuge bei der maximalen Anzahl von 200, 250 und 300 Fahrzeugen der zentralisierten Kolonnenregelung gegenüber der Referenzstrategie 89
7.6 Darstellung der Verkehrssimulation mit unterschiedlicher Anzahl an Fahrzeugen und der beiden Strategien in Fundamentaldiagrammen 91
7.7 Darstellung des Energiebedarfs und der durchschnittlichen Geschwindigkeit aller Fahrzeuge bei $n_{\mathrm{Fzg,max}} = 200$ und mit 5, 10, 15 und 20 Kolonnen 93
7.8 Darstellung der Verkehrssimulation mit unterschiedlicher Anzahl an Fahrzeugen mit zentralisierter Kolonnenregelung im Fundamentaldiagramm bei $n_{\mathrm{Fzg,max}} = 200$ und mit 5, 10, 15 und 20 Kolonnen 94
7.9 Darstellung des Energiebedarfs und der durchschnittlichen Geschwindigkeit aller Fahrzeuge bei $n_{\mathrm{Fzg,max}} = 200$, 250 und 300 sowie mit $N_{\mathrm{p}} = 15$ und 30 s 95
7.10 Darstellung der Verkehrssimulation mit unterschiedlicher Anzahl an Fahrzeugen mit zentralisierter Kolonnenregelung im Fundamentaldiagramm mit $N_{\mathrm{p}} = 15$ und 30 s . . . 95

A.1.1 Darstellung des Antriebsstrangs von einem batterieelektrischen Fahrzeug 118
A.2.1 Aufbau eines künstlichen Neurons j mit n Eingängen 119
A.3.1 Prinzip einer MPR nach [129] 122

Tabellenverzeichnis

5.1 Eingangsdaten des Prädiktionsmodells des Vorausfahrzeugs 34
5.2 Eingangsdaten des Prädiktionsmodells für umliegende nicht-automatisierte Fahrzeuge . 36
5.3 Trainierte Netztopologie für das Prädiktionsmodell des Vorausfahrzeugs 38
5.4 Trainierte Netztopologie für das Prädiktionsmodell des Fahrstreifenwechsels 39
5.5 Hyperparameter der Trainingsprozesse 40
5.6 Median der absoluten longitudinalen und lateralen Positionsfehler in Meter 43

6.1 Simulierter Energiebedarf mit unterschiedlichen Prädiktionshorizonten und Prädiktionsmodellen 54

7.1 Energiebedarf und durchschnittliche Geschwindigkeit der zentralisierten Kolonnenregelung und der Referenzstrategie bei unterschiedlichen Verkehrsdichten 84

A.1.1 Parametereinstellung für das IDM-Fahrermodell in SUMO 114
A.1.2 Parametereinstellung für das NAF IDM-Fahrermodell in SUMO 115
A.1.3 Mittelwert der Parametereinstellung für das IDM in SUMO 115
A.1.4 Fahrzeugklasse und Anteil am Pkw-Bestand in SUMO 116
A.1.5 Fahrzeugparamter Teil 1 116
A.1.6 Fahrzeugparamter Teil 2 117
A.1.7 Fahrzeugparamter Teil 3 117
A.3.1 Simulationsparameter 123

Symbolverzeichnis

Griechische Zeichen

α	Fahrbahnsteigung
β_1	Gradientenabfallfaktor
β_2	Quadratischer Gradientenabfallfaktor
Δs	Straßenabschnitt
Δt	Zeitabschnitt
δ	Beschleunigungsexponent
Δv	Geschwindigkeitsdifferenz
ϵ	Teiler-Summand; Schlupfvariable
$\boldsymbol{\epsilon}$	Schlupfvariable
$\epsilon_{\max}$	Maximale Schlupfvariable
$\epsilon_{\min}$	Minimale Schlupfvariable
η_{G}	Getriebewirkungsgrad
η	Lernrate
η_0	Initiale Lernrate
ρ	Verkehrsdichte
ρ_{krit}	Kritische Verkehrsdichte
ρ_{L}	Luftdichte
$\rho_{\max}$	Maximale Verkehrsdichte
σ_0	Aktivierung eines Biasneuron
σ_{j}	Aktivierung eines künstlichen Neurons
θ_{j}	Schwellwert eines künstlichen Neurons
φ	Aktivierungsfunktion eines künstlichen Neurons

Lateinische Zeichen

a	Beschleunigung
a_0	Wunschbeschleunigung
$\boldsymbol{A}$	Zustandsraummatrix
a_{Ego}	Beschleunigung des Egofahrzeugs

$\boldsymbol{A_{FF}}$	Systemmatrix des Folgefahrzeugs
$a_{\mathrm{FF,neg}}$	Negative Beschleunigung des Folgefahrzeugs
$a_{\mathrm{FF,soll,neg}}$	Gewünschte negative Beschleunigung des Folgefahrzeugs
$a_{\mathrm{FF,pos}}$	Positive Beschleunigung des Folgefahrzeugs
$a_{\mathrm{FF,soll,pos}}$	Gewünschte positive Beschleunigung des Folgefahrzeugs
$a_{\mathrm{FF,VF,neg}}$	Negative Beschleunigung des Vorausfahrzeugs vom Folgefahrzeug
$a_{\mathrm{FF,VF,soll,neg}}$	Gewünschte negative Beschleunigung des Vorausfahrzeugs vom Folgefahrzeug
$a_{\mathrm{FF,VF,pos}}$	Positive Beschleunigung des Vorausfahrzeugs vom Folgefahrzeug
$a_{\mathrm{FF,VF,soll,pos}}$	Gewünschte positive Beschleunigung des Vorausfahrzeugs vom Folgefahrzeug
$\boldsymbol{A_{KF}}$	Systemmatrix des Kolonnenführers
$a_{\mathrm{KF,neg}}$	Negative Beschleunigung des Kolonnenführers
$a_{\mathrm{KF,soll,neg}}$	Gewünschte negative Beschleunigung des Kolonnenführers
$a_{\mathrm{KF,pos}}$	Positive Beschleunigung des Kolonnenführers
$a_{\mathrm{KF,soll,pos}}$	Gewünschte positive Beschleunigung des Kolonnenführers
a_{NAF}	Beschleunigung des nicht-automatisierten Fahrzeugs
A_{q}	Querspantfläche
a_{ref}	Referenzbeschleunigung
a_{VF}	Beschleunigung des vorausfahrenden Fahrzeugs
b_0	Maximale Verzögerung
$\boldsymbol{B}$	Zustandsraummatrix
b_{i}	Bias für den Zellwert
b_{f}	Bias des Forget Gates
$\boldsymbol{B_{FF}}$	Systemmatrix des Folgefahrzeugs
b_{i}	Bias des Input Gates
$\boldsymbol{B_{KF}}$	Systemmatrix des Kolonnenführers
b_{krit}	Maximale Verzögerung in kritischer Situation
$b_{\mathrm{LSA,ge}}$	Lichtsignalanlage-Schaltung Gelb
$b_{\mathrm{LSA,gr}}$	Lichtsignalanlage-Schaltung Grün
$b_{\mathrm{LSA,r}}$	Lichtsignalanlage-Schaltung Rot
b_{o}	Bias des Output Gates
b_{Rcht}	Fahrtrichtungsanzeiger des NAF

b_{VF2}	Status des vorausfahrenden Fahrzeugs vom vorausfahrenden Fahrzeugs
$\boldsymbol{C}$	Zustandsraummatrix
$\tilde{c}_{\mathrm{t}}$	Neuer Kandidat für den Zellwert
c_{t}	Zellzustand
$c_{\mathrm{t}-1}$	Ehemaliger Zellzustand
c_{w}	Luftwiderstandsbeiwert
d	Abstand
d_0	Mindestabstand
d_{AF}	Abstand des automatisierten Fahrzeugs zum Kolonnenführer
$d_{\mathrm{EF,KF}}$	Abstand zwischen dem einscherenden Fahrzeug und Kolonnenführer
$d_{\mathrm{EF,KF,ref}}$	Referenzabstand zwischen dem einscherenden Fahrzeug und Kolonnenführer
$d_{\mathrm{EF,max}}$	Maximaler Abstand zwischen dem einscherenden Fahrzeug und Kolonnenführer
$d_{\mathrm{EF,min}}$	Minimaler Abstand zwischen dem einscherenden Fahrzeug und Kolonnenführer
d_{Ego}	Abstand zum vorausfahrenden Fahrzeuge
$d_{\mathrm{Ego,NAF}}$	Abstand zwischen Egofahrzeug und nicht-automatisiertem Fahrzeug
d_{FF}	Abstand zum vorausfahrenden Fahrzeug von einem Folgefahrzeug
$d_{\mathrm{FF,n_{einscheren},ref}}$	Referenzabstand für das einscherende Fahrzeug zum Kolonnenführer
$d_{\mathrm{FF,n_{einscheren}}}$	Abstand für das einscherende Fahrzeug zum Kolonnenführer
$d_{\mathrm{FF,n}}$	Abstand zwischen FF und seinem Vorausfahrzeug
$d_{\mathrm{FF,VF}}$	Zurückgelegte Strecke des Vorausfahrzeugs vom Folgefahrzeug
$d_{\mathrm{LSA,NAF}}$	Abstand vom NAF zur nächsten Lichtsignalanlage
$d_{\mathrm{LSA,VF1}}$	Abstand vom Vorausfahrzeug zur nächsten Lichtsignalanlage
d_{max}	Maximaler Abstand
d_{min}	Minimaler Abstand
$d_{\mathrm{NAF,KF}}$	Abstand des nicht-automatisierten Fahrzeugs zu Kolonnenführer
$d_{\mathrm{NAF,KF,ref}}$	Referenzabstand des nicht-automatisierten Fahrzeugs zu Kolonnenführer

$d_{\mathrm{NAF,max}}$	Maximaler Abstand des nicht-automatisierten Fahrzeugs zum Kolonnenführer
$d_{\mathrm{NAF,min}}$	Minimaler Abstand des nicht-automatisierten Fahrzeugs zum Kolonnenführer
d_{ref}	Referenzabstand
d_{VF1}	Abstand zwischen zwei vorausfahrenden Fahrzeugen
d_{weich}	Abstand der weichen Nebenbedingung
$\bar{E}_{\mathrm{Fzg}}$	Durchschnittlicher Energiebedarf
e_{i}	Massenfaktor
f_{η}	Lernratenreduktionsfaktor
f_{r}	Rollwiderstandsbeiwert
f^{Sig}	Sigmoidfunktion
f_{t}	Ausgabe des Forget Gates
$f^{\tanh}$	Tangens hyperbolicus Funktion
F_{Trak}	Traktionskraft
$\boldsymbol{G}$	Zustandsraummatrix
g	Erdbeschleunigung
$\boldsymbol{G_{\mathrm{FF}}}$	Störgrößenvektor des Folgefahrzeugs
h_{t}	Versteckter Status eines RNN
$h_{\mathrm{t-1}}$	Versteckter Status des vorherigen Zeitschritts eines RNN
I	Optimierungsintervall
i_{G}	Getriebeübersetzung
i_{t}	Zwischenergebnis des Input Gates eines LSTMs
J	Kostenfunktion
$j_{\mathrm{FF,neg}}$	Negativer Ruck des Folgefahrzeugs
$j_{\mathrm{FF,pos}}$	Positiver Ruck des Folgefahrzeugs
$j_{\mathrm{KF,neg}}$	Negativer Ruck des Kolonnenführers
$j_{\mathrm{KF,pos}}$	Positiver Ruck des Kolonnenführers
j_{ref}	Referenzruck
k	Zeitpunkt k
L	Fehler während des Trainingsprozesses
l_{Fzg}	Fahrzeuglänge
l_{NAF}	Fahrzeuglänge des nicht-automatisierten Fahrzeugs

m	Fahrzeugmasse
M_{EM}	Drehmoment des Elektromotors
$M_{\mathrm{EM,min}}$	Negative Drehmomentgrenze des Elektromotors
M_{Trak}	Traktionsmoment
$M_{\mathrm{Trak,min}}$	Minimales Traktionsmoment
N_{c}	Stellhorizont
$n_{\mathrm{einscheren}}$	Einscherposition
n_{EM}	Drehzahl des Elektromotors
$n_{\mathrm{Fzg,ges}}$	Gesamtanzahl der Fahrzeuge
$n_{\mathrm{Fzg,max}}$	Maximale Fahrzeuganzahl
$n_{\mathrm{Fzg,ges}}$	Zeitabschnitt
n_{iter}	Maximale Berechnungsiteration der MPR
N_{p}	Prädiktionshorizont
$n_{\mathrm{q,Fzg,ges}}$	Anzahl an Fahrzeugen zur Berechnung der Verkehrsstärke
$n_{\rho\mathrm{,Fzg,ges}}$	Anzahl an Fahrzeugen zur Berechnung der Verkehrsdichte
o_{t}	Ausgabe des Output Gates
$P_{\mathrm{Batt,el}}$	Elektrische Leistung der Batterie
$P_{\mathrm{Batt,chem}}$	Chemische Leistung der Batterie
$P_{\mathrm{DC-DC}}$	Elektrische Leistung des Gleichspannungswandlers
$P_{\mathrm{EM,el}}$	Elektrische Leistung des Elektromotors
$P_{\mathrm{EM,mech}}$	Mechanische Leistung des Elektromotors
$P_{\mathrm{EM,min}}$	Minimale Leistungsgrenze des Elektromotors
$P_{\mathrm{EM,verlust}}$	Verlustleistung des Elektromotors
q	Verkehrsstärke
$q_{\mathrm{Besch/Verz}}$	Gewichtungsfaktor für Beschleunigung und Verzögerung
$Q_{\mathrm{besch/verz,EF}}$	Gewichtungsfaktor der Beschleunigung und Verzögerung vom einscherenden Fahrzeug
$\boldsymbol{Q_{\mathrm{AF}}}$	Gewichtungsfaktor des automatisierten Fahrzeugs
$Q_{\mathrm{besch/verz,FF}}$	Gewichtungsfaktor der Beschleunigung und Verzögerung vom Folgefahrzeug
$Q_{\mathrm{besch/verz,FF,n_{einscheren}+1}}$	Gewichtungsfaktor der Beschleunigung und Verzögerung vom Folgefahrzeug hinter dem einscherenden Fahrzeug
Q_{besch}	Gewichtungsfaktor der Beschleunigung

$\boldsymbol{Q}$	Gewichtungsmatrix
$Q_{\mathrm{d,EF}}$	Gewichtungsfaktor des Abstands vom einscherenden Fahrzeug
$Q_{\mathrm{d,FF}}$	Gewichtungsfaktor des Abstands des Folgefahrzeugs
$Q_{\mathrm{d,FF,n_{einscheren}+1}}$	Gewichtungsfaktor des Abstands vom Folgefahrzeug hinter dem einscherenden Fahrzeug
$\boldsymbol{q_\epsilon}$	Gewichtungsfaktor der Schlupfvariablen
q_ϵ	Gewichtungsfaktor der Schlupfvariable
q_{max}	Maximale Verkehrsstärke
$Q_{\mathrm{ruck,neg}}$	Gewichtungsfaktor des negativen Rucks
$Q_{\mathrm{ruck,pos}}$	Gewichtungsfaktor des positiven Rucks
$Q_{\mathrm{s,KF}}$	Gewichtungsfaktor der zurückgelegten Strecke des Kolonnenführers
Q_{v}	Gewichtungsfaktor der Geschwindigkeit
$Q_{\mathrm{v,EF}}$	Gewichtungsfaktor der Geschwindigkeit vom einscherenden Fahrzeug
Q_{verz}	Gewichtungsfaktor der Verzögerung
$Q_{\mathrm{v,FF}}$	Gewichtungsfaktor der Geschwindigkeit vom Folgefahrzeug
$Q_{\mathrm{v,FF,n_{einscheren}+1}}$	Gewichtungsfaktor der Geschwindigkeit vom Folgefahrzeug hinter dem einscherenden Fahrzeug
$\boldsymbol{R_{\mathrm{AF}}}$	Gewichtungsfaktor des automatisierten Fahrzeugs
$\boldsymbol{R}$	Gewichtungsmatrix
$\boldsymbol{r}$	Referenztrajektorie
r_{dyn}	Dynamische Radhalbmesser
$\boldsymbol{r_{\mathrm{FF}}}$	Referenztrajektorie des Folgefahrzeugs
R_{i}	Innenwiderstand
$\boldsymbol{r_{\mathrm{KF}}}$	Referenztrajektorie des Kolonnenführers
$s_{\mathrm{AF,akt}}$	Aktuelle zurückgelegte Strecke des aufschließenden Fahrzeugs
s_{akt}	Aktuelle zurückgelegte Strecke
$s_{\mathrm{EF,akt}}$	Aktuelle zurückgelegte Strecke des einscherenden Fahrzeugs
$s_{\mathrm{Fzg,i}}$	Fahrzeugposition, zurückgelegte Strecke
s_{KF}	Zurückgelegte Strecke des Kolonnenführers
$s_{\mathrm{KF,akt}}$	Aktuelle zurückgelegte Strecke des Kolonnenführers
$s_{\mathrm{KF,Präd}}$	Prädizierte zurückgelegte Strecke des Kolonnenführers

s_{LSA}	Position der Lichtsignalanlage
s_{m}	Ort für lokale Kenngröße
$s_{\mathrm{NAF,Präd}}$	Prädizierte zurückgelegte Strecke des nicht-automatisierten Fahrzeugs
$s_{\mathrm{Präd}}$	Prädizierte zurückzulegende Strecke
s_{VF}	Zurückgelegte Strecke des Vorausfahrzeugs
$s_{\mathrm{VF,Präd}}$	Prädizierte zurückgelegte Strecke des Vorausfahrzeugs
T	Zeitschritt der Eingabensequenz
T_0	Wunschzeitabstand
$T_{\mathrm{a,besch}}$	Zeitkonstante der Übertragungsfunktion für Beschleunigung
$T_{\mathrm{a,verz}}$	Zeitkonstante der Übertragungsfunktion für Verzögerung
t_{d}	Zeitabstand
$t_{\mathrm{d,AF,max}}$	Maximaler Zeitabstand des automatisierten Fahrzeugs zum Kolonnenführer
$t_{\mathrm{d,max}}$	Maximaler Zeitabstand
$t_{\mathrm{d,min}}$	Minimaler Zeitabstand
$t_{\mathrm{d,ref}}$	Referenzzeitabstand
$t_{\mathrm{Grün,Beginn,2}}$	Beginn der zweiten grünen Phase
$t_{\mathrm{Grün,Ende,1}}$	Ende der ersten grünen Phase
ti_{LSA}	Verbleibende Anzeigedauer aktueller Lichtsignalanlage-Schaltung
Δt_{MPR}	MPR Schrittweite
Δt_{Sim}	Simulationsschrittweite
t_{VF}	Zeitabstand des Vorausfahrzeugs
U_0	Ruhespannung
$\boldsymbol{u}$	Stellgrößenvektor
$\boldsymbol{u_{\mathrm{max}}}$	Maximaler Stellgrößenvektor
$\boldsymbol{u_{\mathrm{min}}}$	Minimaler Stellgrößenvektor
$\boldsymbol{u_{\mathrm{FF}}}$	Stellgrößenvektor des Folgefahrzeugs
$\boldsymbol{u_{\mathrm{KF}}}$	Stellgrößenvektor des Kolonnenführers
v	Geschwindigkeit
v_0	Wunschgeschwindigkeit
v_{AF}	Geschwindigkeit des aufschließenden Fahrzeugs
$v_{\mathrm{AF,akt}}$	Aktuelle Geschwindigkeit des aufschließenden Fahrzeugs

$\bar{v}_{\mathrm{m}}$	Durchschnittliche momentane Geschwindigkeit
$v_{\max}$	Wunschgeschwindigkeit
$\bar{v}_{\max}$	Maximale durchschnittliche Geschwindigkeit
$\bar{v}_{\mathrm{m/l}}$	Durchschnittliche momentane und lokale Geschwindigkeit
$\boldsymbol{v}$	Störgrößenvektor
v_{EF}	Geschwindigkeit des einscherenden Fahrzeugs
$v_{\mathrm{EF,akt}}$	Aktuelle Geschwindigkeit des einscherenden Fahrzeugs
v_{Ego}	Longitudinale Geschwindigkeit des Egofahrzeugs
v_{FF}	Geschwindigkeit des Folgefahrzeugs
$v_{\mathrm{FF,VF}}$	Geschwindigkeit des Vorausfahrzeugs vom Folgefahrzeug
v_{Fzg}	Fahrzeuggeschwindigkeit
$\bar{v}_{\mathrm{Fzg}}$	Durchschnittliche Fahrzeuggeschwindigkeit
v_{KF}	Geschwindigkeit des Kolonnenführers
v_{krit}	Kritische Geschwindigkeit
$v_{\mathrm{NAF,Lat}}$	Laterale Geschwindigkeit des nicht-automatisierten Fahrzeugs
v_{lim}	Maximale zulässige Geschwindigkeitsbegrenzung
$v_{\mathrm{NAF,Long}}$	Longitudinale Geschwindigkeit des nicht-automatisierten Fahrzeugs
v_{m}	Momentane Geschwindigkeit
$v_{\min}$	Minimale Geschwindigkeit
$v_{\mathrm{m/l}}$	momentane und lokale Geschwindigkeit
$v_{\mathrm{NAF,Präd}}$	Prädizierte Geschwindigkeit des nicht-automatisierten Fahrzeugs
$v_{\mathrm{NAF,ref}}$	Referenzgeschwindigkeit des nicht-automatisierten Fahrzeugs
v_{NAF}	Geschwindigkeit des nicht-automatisierten Fahrzeugs
v_{Toleranz}	Toleranzgeschwindigkeit
v_{VF}	Geschwindigkeit des vorausfahrenden Fahrzeugs
v_{VF1}	Longitudinale Geschwindigkeit des Vorausfahrzeugs
v_{VF2}	Longitudinale Geschwindigkeit des vorausfahrenden Fahrzeugs vom vorausfahrenden Fahrzeug
$\boldsymbol{w}$	Sollwertvektor, Störgrößen
W_{i}	Gewichtungsfaktor für den Zellwert
W_{f}	Gewichtungsfaktor des Forget Gates
$\boldsymbol{w_{\mathrm{FF}}}$	Störgrößenvektor des Folgefahrzeugs

W_{i}	Gewichtungsfaktor des Input Gates
W_{nj}	Gewichtungen eines künstlichen Neurons
W_{o}	Gewichtungsfaktor des Output Gates
x_{25}	Unteres Quatil
x_{75}	Oberes Quartil
$\boldsymbol{x_{\mathbf{max}}}$	Maximaler Zustandsgrößenvektor
$\boldsymbol{x_{\mathbf{min}}}$	Minimaler Zustandsgrößenvektor
$\boldsymbol{\dot{x}_{\mathbf{FF}}}$	Ableitung des Zustandsgrößenvektors von einem Folgefahrzeug
$\boldsymbol{\dot{x}_{\mathbf{KF}}}$	Ableitung des Zustandsgrößenvektors von einem Kolonnenführer
$\boldsymbol{x_{\mathbf{FF}}}$	Zustandsgrößenvektor von einem Folgefahrzeug
$\boldsymbol{x_{\mathbf{FF,VF}}}$	Zustandsgrößenvektor des Vorausfahrzeugs von einem Folgefahrzeug
x_{i}	Sequentierte Trainingsdaten Eingaben
$\boldsymbol{x_{\mathbf{KF}}}$	Zustandsgrößenvektor des Kolonnenführers
x_{med}	Statistischer Median
x_{t}	Externe Eingänge eines RNN
$\boldsymbol{x}$	Zustandsgrößenvektor
$\boldsymbol{y}$	Ausgangsgrößenvektor
$\hat{y}_{\mathrm{i}}$	Prädiktion während des Trainingsprozesses
y_{i}	Labels

Abkürzungsverzeichnis

Akronyme

AF	Aufschließendes Fahrzeug
ASF	Ausscherendes Fahrzeug
AUF	Automatisiertes Umgebungsfahrzeug
BP	Backpropagation
C-CACC	Centralized Cooperative Adaptive Cruise Control
CLG	Conditional Linear Gauss
CNN	Convolutional Neural Networks
DSRC	Dedicated Short Range Communication
EF	Einscherendes Fahrzeug
FF	Folgefahrzeuge
FFE	Fahrer-Fahrzeug-Einheit
GPS	Global Positioning System
HD	High Definition
IDM	Intelligent Driver Model
KF	Kolonnenführer
KNN	Künstliches Neuronales Netzwerk
Lkw	Lastkraftwagen
LQR	Linearer Quadratischer Regler
LSA	Lichtsignalanlage
LSTM	Long Short-Tern Memory
ML	Maschinelles Lernen
MLP	Multilayer Perceptron
MPR	Modellprädiktive Regelung
NAF	Nicht-automatisiertes Fahrzeug
OSM	OpenStreetMap
PID	Proportional-integral-derivative
Pkw	Personenkraftwagen
PSDDPG	Platoon Sharing Deep Deterministic Policy Gradient Algorithmus

RL	Reinforcement Learning
RNN	Rekurrente Neuronale Netze
SUMO	Simulation of Urban MObility
TraCI	Traffic Control Interface
V2I	Vehicle-to-Infrastructure
V2V	Vehicle-to-Vehicle
V2X	Vehicle-to-Everything
VF	Vorausfahrzeug
ViL	Vehicle-in-the-Loop
WLTC	Worldwide harmonized Light vehicles Test Cycle

1 Einleitung

1.1 Hintergrund und Motivation automatisierter und vernetzter Fahrzeugführung

In Anbetracht der allgegenwärtigen klimatischen Herausforderungen rücken automatisierte und vernetzte Fahrsysteme, insbesondere aufgrund ihrer Fähigkeit zur Steigerung der energetischen Effizienz von Fahrzeugen, verstärkt in den wissenschaftlichen Fokus. Durch eine energetisch optimierte Fahrzeugführung ist es möglich, sowohl die Reichweiten elektrifizierter Antriebsstränge zu erhöhen als auch Schadstoffemissionen konventioneller Verbrennungsmotoren zu reduzieren. Im Rahmen der Mobilität der Zukunft sind neben der Minimierung verkehrsbedingter Emissionen auch die Optimierung des Verkehrssystems und die Gewährleistung einer erhöhten Sicherheit für sämtliche Verkehrsteilnehmer zentrale Aspekte. Die Interaktion und Kommunikation zwischen automatisierten und vernetzten Fahrzeugen kann maßgeblich dazu beitragen, die Zielvorgaben hinsichtlich Emissionsminderung, Maximierung der Energieeffizienz und Minimierung von Verkehrsunfällen zu erreichen.
Eine Voraussetzung zur Umsetzung automatisierter und vernetzter Fahrfunktionen ist die Erfassung und Analyse umfangreicher Datenmengen aus der Verkehrsumgebung sowie eine darauf basierende Fahrzeugführung. Insbesondere stellen städtische Verkehrsszenarien automatisierte Fahrzeuge vor große Herausforderungen. Ein kritischer Aspekt sind Kreuzungen und Lichtsignalanlagen, die je nach gegebener Verkehrslage eine Anpassung der Fahrgeschwindigkeit erfordern. Durch eine rechtzeitige Übermittlung des Schaltprogramms mittels moderner Kommunikationstechnologien an die Fahrzeuge kann durch prädiktive kooperative Fahrfunktion eine effizientere und vorausschauende Fahrtrajektorienplanung realisiert werden. Hinzu kommt die besondere Dynamik des Stadtverkehrs, der durch eine hohe Frequenz an Fahrstreifenwechseln gekennzeichnet ist. Fahrstreifenwechsel, häufig begleitet von einer Verzögerung benachbarter Fahrzeuge, haben einen erheblichen Einfluss auf den Gesamtverkehrsfluss und dessen Effizienz. Zur effizienten und sicheren Navigation automatisierter Fahrzeuge durch den Straßenverkehr können diese von Vorwissen über die kurzfristigen Intentionen umgebender Verkehrsteilnehmer profitieren. Ein solches Vorwissen ermöglicht es, die Fahrgeschwindigkeit durch prädiktive kooperative Fahrfunktion antizipatorisch anzupassen, das nicht nur die Durchführung von Fahrstreifenwechseln erleichtert, sondern auch sicherstellt, dass der gesamte Verkehrsfluss nur geringfügig beeinträchtigt wird.
Trotz der offensichtlichen Vorteile prädiktiver kooperativer Fahrfunktion für die Erhöhung von Energie- und Verkehrseffizienz wurde bisher keine systematische Untersuchung zu diesem Thema durchgeführt. Vereinzelte wissenschaftliche Arbeiten haben sich mit partiellen Aspekten kooperativer Fahrfunktionen im Kontext der Optimierung des Energiebedarfs und der Verkehrseffizienz in bestimmten Verkehrsszenarien auseinandergesetzt. Dennoch fehlt eine ganzheitliche und methodische Untersuchung, die das Gesamtpotenzial dieser Fahrfunktionen umfassend analysiert. Dafür müssen die Herausforderungen erkannt und wissenschaftlich beschrieben sowie untersucht werden.
Zum einen stellt die Kommunikationstechnologie eine erforderliche Komponente für kooperative

Fahrfunktionen dar, um einen Informationsaustausch zwischen den Fahrzeugen sicherzustellen. Darüber hinaus muss gewährleistet sein, dass Informationen über die Verkehrsinfrastruktur rechtzeitig an die Fahrzeuge übertragen werden, um eine energetisch optimierte Fahrtrajektorienplanung zu ermöglichen. Aktuell existiert keine Testumgebung, die solch einen Austausch ermöglicht und zugleich ein realistisches Verkehrssystem abbildet. Des Weiteren erfordert eine prädiktive kooperative Fahrfunktion, aufgrund der Verarbeitung umfangreicher Datenmengen und der Optimierung von Fahrtrajektorien, eine signifikante Rechenkapazität, welche durch aktuelle Fahrzeugsteuergeräte nicht bereitgestellt werden kann. Schlussendlich besteht die Herausforderung darin, Methoden und Algorithmen zu entwickeln, die nicht nur Sicherheit und Komfort im automatisierten Fahren gewährleisten, sondern auch die Effizienz hinsichtlich des Energiebedarfs und des Verkehrsflusses steigern.

1.2 Zielsetzung und Vorgehensweise

Angesicht der genannten Vorteile und Herausforderungen verfolgt die vorliegende Dissertationsschrift das Ziel, durch prädiktive kooperative Fahrfunktion die Energie- und Verkehrseffizienz im städtischen Gebiet zu verbessern. Daraus ergibt sich folgende Forschungshypothese:

Durch Einsatz prädiktiver kooperativer Fahrfunktion kann die Energie- und Verkehrseffizienz im städtischen Gebiet verbessert werden.

Aus dieser Hypothese leiten sich folgende Forschungsfragen ab:

- Wie ist eine prädiktive kooperative Fahrfunktion zu konzipieren, die über eine vorausschauende und energetisch optimierte Fahrzeuglängsführung in städtischen Verkehrsbedingungen hinausgeht und zugleich Fahrmanöver ganzheitlich koordiniert, um den Verkehrsfluss zu verbessern?
- Inwiefern beeinflusst die Intention der umgebenden Verkehrsteilnehmer die Funktionalität der prädiktiven kooperativen Fahrfunktion und wie kann diese vorausgesagt werden?
- In welchen Verkehrsszenarien kann durch den Einsatz einer prädiktiven kooperativen Fahrfunktion eine Steigerung der Energie- und Verkehrseffizienz realisiert werden, und welches quantitative Einsparpotenzial lässt sich hierbei erzielen?

Zur Beantwortung dieser Forschungsfragen wird die vorliegende Dissertationsschrift wie folgt aufgebaut. Nach einer umfassenden Betrachtung der Grundlagen und des Stands der Technik, hinsichtlich vernetzter und automatisierter Fahrzeugführung in Kapitel 2, fokussiert sich Kapitel 3 auf die Konzeption und Implementierung einer Co-Simulationsplattform, die zur Validierung prädiktiver kooperativer Fahrfunktion verwendet werden kann.
Im Anschluss wird in Kapitel 4 der Aufbau einer passenden Simulationsumgebung erläutert. Diese gewährleistet eine realistische Abbildung sowohl von Verkehrsszenarien als auch des Fahrzeugantriebssystems, um die Auswirkung prädiktiver kooperativer Fahrfunktion auf Energiebedarf und Verkehrsfluss unter realitätsnahen Bedingungen zu evaluieren. Zum Aufbau der Straßennetze und

zur Abbildung des stochastischen Verkehrsflusses wird das Netz-, Verkehrsnachfrage- und Verhaltensmodell modelliert. Für die energetische Analyse wird darüber hinaus ein Modell eines batterieelektrischen Fahrzeugs herangezogen. Zur Ermittlung der Eigenschaften der Simulationsumgebung wird diese verifiziert und anhand relevanter Verkehrskenngrößen charakterisiert.
Im darauf folgenden Kapitel 5 erfolgt die Entwicklung der Trajektorienprädiktion umgebender Verkehrsteilnehmer. Zwei Methoden werden eingeführt und untersucht. Für die Prädiktion der longitudinalen Geschwindigkeit des unmittelbar vorausfahrenden Fahrzeugs erfolgt eine Erweiterung und Anpassung des in [1] vorgestellten Modells. Zur Prädiktion sowohl der longitudinalen als auch der lateralen Geschwindigkeiten von Fahrzeugen auf benachbarten Fahrstreifen während des Fahrstreifenwechselmanövers wird ein auf maschinellem Lernen basierendes Prädiktionsmodell entwickelt. Nach einer detaillierten Erläuterung der Datengenerierung und -verarbeitung erfolgt das Training der genannten Modelle. Abschließend wird die Genauigkeit beider Ansätze evaluiert.
Im Kapitel 6 erfolgt die Entwicklung der prädiktiven kooperativen Fahrfunktion. In einem ersten Schritt wird eine zentralisierte kooperative Fahrfunktion für das Folgefahrtszenario konzipiert und implementiert. Der Energiebedarf und die Verkehrsdichte werden in einem ausgewählten Szenario evaluiert. Basierend auf diesen Erkenntnissen erfolgt die Einführung des Konzepts für das kooperative Fahrmanövermanagement, welches das Aufschließen, Einscheren, Ausscheren und Aufteilen ganzheitlich koordiniert. Hierbei wird eine mikroskopische Untersuchung der einzelnen Fahrmanöver durchgeführt, wobei insbesondere die Analyse der Fahrtrajektorien im Fokus steht.
Im anschließenden Kapitel 7 wird eine umfassende Analyse sowohl auf mikroskopischer als auch auf makroskopischer Ebene durchgeführt. Ziel dieser Untersuchung ist es, die Auswirkungen der implementierten Fahrfunktion hinsichtlich des Energiebedarfs und des Verkehrsflusses festzustellen. Hierbei wird nicht nur der Fokus auf die durch die Fahrfunktion gesteuerten Fahrzeuge gelegt, sondern ebenfalls eine ganzheitliche Betrachtung sämtlicher Verkehrsteilnehmer innerhalb der Simulationsumgebung vorgenommen. Abschließend wird eine Parametervariation der kooperativen Fahrfunktion implementiert, um deren Einfluss auf das gesamte Verkehrsgeschehen detailliert zu evaluieren.

2 Grundlagen vernetzter und automatisierter Fahrzeugführung

Seit geraumer Zeit besteht ein wissenschaftliches Interesse daran, sämtliche Verkehrsteilnehmer mittels Kommunikationstechnologien zu vernetzen, um den Informationsaustausch zu ermöglichen. Die Integration dieser Technologien bildet das Fundament für das kooperative und automatisierte Fahren, welches in der heutigen Mobilitätsforschung eine zentrale Rolle einnimmt. Die Funktionsstruktur der kooperativen Fahrfunktionen baut auf mehreren Komponenten auf und wird in Abbildung 2.1 dargestellt.

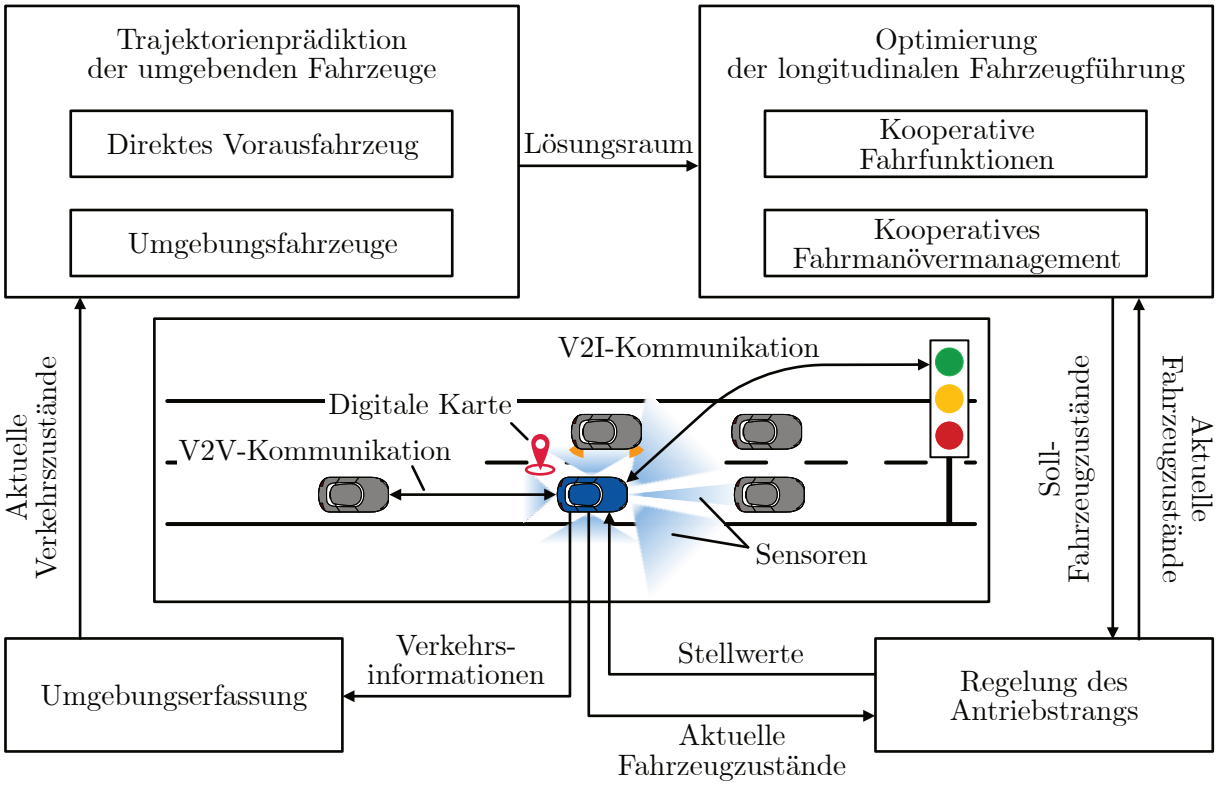

Abbildung 2.1: Funktionsstruktur der kooperativen Fahrfunktionen nach [2]

Auf Basis der erfassten Verkehrszustände bildet die Trajektorienprädiktion der umgebenden Fahrzeuge und die Optimierung der longitudinalen Fahrzeugführung ein gemeinsames Funktionsmodul der energieeffizienten Fahrzeuglängsführung. Unter Anwendung der erfassten Verkehrszustände können Prädiktionsalgorithmen genutzt werden, um zukünftige Fahrtrajektorien der umgebenden Fahrzeuge zu bestimmen. Daraufhin kann eine Optimierung der longitudinalen Fahrzeugführung für jeden Ausführungszeitpunkt innerhalb des ermittelten Lösungsraums durchgeführt werden. Die Lösung der Optimierung wird als Soll-Fahrzeugzustände an die Regelung des Antriebsstrangs weitergeleitet, während die aktuellen Fahrzeugzustände zur Berechnung der Sollwerte für den nächsten Zeitschritt an die Optimierung zurückgesendet werden.
Im nachfolgenden Abschnitt erfolgt eine detaillierte Darstellung unterschiedlicher Informationsquellen, die für die Erfassung der Fahrzeugumgebung zum Einsatz kommen. Darüber hinaus werden

Algorithmen, welche in der Fachliteratur für die Trajektorienprädiktion und die Optimierung der longitudinalen Fahrzeugführung in Bezug auf kooperative Fahrfunktionen und Fahrmanövermanagement beschrieben werden, eingehender erläutert.

2.1 Umgebungserfassung

Die zur Prädiktion der umgebenden Fahrzeuge benötigten Verkehrsinformationen werden aus drei unterschiedlichen Quellen gewonnen: Sensorik, digitale Karten und Vehicle-to-Everything (V2X)-Kommunikation. Aktuelle Fahrzeuge verwenden eine Vielzahl von Sensoren zur Datenerfassung, einschließlich Radarsensoren [3], LiDAR-Sensoren [4] und optische Sensoren [5]. Die Radar- und LiDAR-Sensoren sind in der Lage, umliegende Objekte zu identifizieren, zu klassifizieren und präzise Messungen von Abständen und Relativgeschwindigkeiten durchzuführen. Optische Sensoren, wie Kamerasensoren, erfassen und verarbeiten Bildinformationen aus der Fahrzeugumgebung. Durch den Einsatz von maschinellem Sehen ist es möglich, unterschiedliche Verkehrsteilnehmer wie andere Fahrzeuge, Fahrräder, Fußgänger und Straßenmarkierungen zu identifizieren. Die Kombination und Fusion von Daten aus verschiedenen Sensoren kann dazu beitragen, ein umfassendes Bild der umgebenden Verkehrsumgebung zu erstellen. [6], [7], [8], [9] Eine Herausforderung der Fahrzeugsensorik besteht in der eingeschränkten Reichweite, die auf die Sichtweite limitiert ist. Präzision und Verlässlichkeit der durch Fahrzeugsensoren generierten Daten können durch eine Vielzahl an Faktoren beeinträchtigt werden, inklusive ungünstiger Wetterbedingungen oder Hindernissen im Straßenverkehr [10], [11]. Solche Einflussgrößen können Schwierigkeiten bei der Objekterkennung hervorrufen und das Fahrzeug dazu veranlassen, potenziell unsichere Manöver durchzuführen.
Die Erfassung von Verkehrsinformationen bietet durch den Einsatz hochauflösender (engl. High Definition, HD) Karten eine zweite bedeutende Option. Diese ermöglichen in Kombination mit Sensordaten eine präzisere Lokalisierung des Fahrzeugs als es allein durch das Global Positioning System (GPS) erreichbar ist. Besonders in städtischen Gebieten mit hohen Gebäudestrukturen kann eine präzise Positionsbestimmung, die den Anforderungen des automatisierten Fahrens genügt, herausfordernd sein. Die Integration von Sensordaten und HD Karten erlaubt eine Positionsbestimmung auf eine Genauigkeit von wenigen Zentimetern. HD Karten versorgen das System zudem mit detailreichen Informationen zur Straßeninfrastruktur, einschließlich der Anzahl an Fahrstreifen, Fahrbahnmarkierungen, Verkehrszeichen sowie Kreuzungen und Lichtsignalanlagen LSA. In diesem Zusammenhang fungieren HD Karten als verifizierende oder ergänzende Quelle zu den erfassten Sensordaten. Zusätzlich liefern HD Karten Daten bezüglich der Verkehrssituation, Geschwindigkeitsbegrenzungen und Informationen über andere Verkehrsteilnehmer. Infolgedessen können die auf HD Karten basierenden Daten, welche über die Erfassungsreichweite der Fahrzeugsensoren hinausgehen, zur Anpassung und Optimierung der Fahrtrajektorie unter Berücksichtigung von Verkehrsregeln und -bedingungen verwendet werden. [12], [13], [14], [15], [16], [17]
Die Datenerfassung von Verkehrssituationen kann durch den Einsatz fortschrittlicher Fahrzeugkommunikationstechnologien erweitert und verbessert werden. Eine herausragende Technologie in diesem Bereich stellt die V2X-Kommunikation dar, die die Interaktion und Vernetzung von Fahrzeugen

untereinander (engl. Vehicle-to-Vehicle, V2V) ermöglicht, aber auch einen Informationsaustausch zwischen Fahrzeugen und Verkehrsinfrastrukturelementen (engl. Vehicle-to-Infrastructure, V2I) sicherstellt [18]. Die Implementierung der V2X-Kommunikation basiert hauptsächlich auf zwei zentralen Technologien: den speziellen Kurzstreckenkommunikationen (engl. Dedicated Short Range Communications, DSRC), auch bekannt als IEEE 802.11p, sowie den Mobilfunkstandards 4G oder 5G [19], [20]. Die V2X-Kommunikation bietet signifikante Vorteile, indem diese es erlaubt, Daten über die aktuellen Fahrzustände, wie Position, Geschwindigkeit oder Beschleunigung, auszutauschen. Zudem wird die Übermittlung von infrastrukturbezogenen Informationen an Fahrzeuge ermöglicht, beispielsweise die geplanten Phasen und Schaltzeiten von LSA. Diese Informationen können genutzt werden, um die optimale Fahrstrecke zu wählen oder eine frühzeitige Anpassung der Geschwindigkeit für ein effizientes Passieren von signalisierten Kreuzungen zu ermöglichen. Die kontinuierliche Weiterentwicklung zuverlässiger und stabiler V2X-Kommunikationstechnologien eröffnet Potenziale für das kooperative Fahren und bietet dadurch Möglichkeiten zur Steigerung der Verkehrseffizienz [21], [22], [23], [24].

2.2 Trajektorienprädiktion der umgebenden Fahrzeugen

Das Vorhersagen zukünftiger Verhalten umgebender Verkehrsteilnehmer eines Egofahrzeugs stellt einen wesentlichen Faktor in der Entwicklung automatisierter Fahrfunktionen für effizientes und sicheres Fahren im Straßenverkehr dar. Die Aufgabe der Trajektorienprädiktion umgebender Fahrzeuge ist anspruchsvoll und erfordert die Berücksichtigung sowohl der dynamischen Verhaltensweisen der beteiligten Fahrzeuge als auch der Wechselwirkungen zwischen diesen. Die Herausforderung besteht darin, zukünftige Verkehrsbedingungen, einschließlich des Fahrverhaltens umliegender Verkehrsteilnehmer, mit den vorhandenen Verkehrsinformationen so genau wie möglich vorherzusagen. Dies kann die Qualität der nachfolgenden Optimierung der Fahrtrajektorie des Egofahrzeugs und damit den Energiebedarf erheblich beeinflussen. Eine Vielzahl an Ansätzen zur Vorhersage der Fahrverhalten von umliegenden Fahrzeugen existiert bereits. Durch die Funktionsweise und die Art der prädizierten Ausgaben lassen diese sich in klassifizierende Methoden zur Prädiktion diskreter Intentionen sowie Modelle zur Prädiktion kontinuierlicher Positionsangaben unterteilen.

Prädiktion diskreter Intentionen

Im Kontext der Trajektorienprädiktion dienen die klassifizierenden Modelle der Vorhersage diskreter Intensionen. In [25] wurde das Verhalten an Kreuzungen von Geradeausfahrt, Rechtsabbiegen oder Linksabbiegen über ein Hidden Markov Modell prädiziert. Hierbei handelt es um ein statistisches Modell, mit dem die Entwicklung beobachtbarer Ereignisse anhand versteckter, interner Faktoren beschrieben werden kann. Zur Vorhersage von Fahrstreifenwechseln wurde die Verwendung von Kalman-Filtern erforscht [26], bei dem der Zustand eines Systems anhand von Messdaten geschätzt wird. Die Fortschritte in der Anwendung maschinellen Lernens (ML) haben den Einsatz künstlicher neuronaler Netze zur Klassifizierung und Prädiktion weiter vorangetrieben. In [27] wurde ein mehrlagiges Perzeptron (engl.: Multilayer Perceptron, MLP) zur Prädiktion lateraler Bewegungen

umliegender Verkehrsteilnehmer verwendet. Basierend auf historischen Eingabedaten prädiziert das Modell die zukünftige Fahrbahn des benachbarten Fahrzeugs und wählt die Trajektorie für den Fahrstreifenwechsel aus. Für die Prädiktion von Fahrtrajektorien an Kreuzungen wurden in [28] und [29] Long Short-Term Memory (LSTM)-Netzwerke eingesetzt, die in der Lage sind, auf Grundlage sequenzieller Eingabedaten und der damit verbundenen zeitlichen Dynamik, zukünftige Zustände zu prädizieren. Die Ausgaben dieser LSTM-Netzwerke dienten zur diskreten Auswahl aus einer Menge repräsentativer Trajektorien.
Ein Vorteil klassifizierender Verhaltensprädiktion besteht darin, dass durch die diskreten Ausgaben das Training der Modelle und deren Evaluation vereinfacht werden. Allerdings werden dadurch nur diskrete und somit qualitative Angaben über die zukünftigen Positionierungen der betrachteten Verkehrsteilnehmer ermöglicht. Daher ist eine Anpassung der Fahrweise des Egofahrzeugs auf Basis dieser Vorhersagen nicht möglich. Um quantitative Vorhersagen über zukünftige Positionen benachbarter Fahrzeuge zu generieren, die für eine effiziente Trajektorienplanung des Egofahrzeuges verwendet werden können, ist die Prädiktion kontinuierlicher Fahrtrajektorien erforderlich.

Prädiktion kontinuierlicher Fahrtrajektorien

Mittels unterschiedlicher Verfahren lassen sich quantitative Positionsinformationen anstatt diskreter Intentionen für einen zukünftigen Zeitintervall von mehreren Sekunden vorhersagen. Beispielsweise wurde in [30] und [1] ein Conditional Linear Gauss (CLG) Modell verwendet, um den Geschwindigkeitsverlauf eines vorausfahrenden Fahrzeugs für einen Zeithorizont von 15 Sekunden zu prädizieren. Dieser Ansatz wurde auf ein reines Fahrzeugfolgeszenario im urbanen Bereich ohne Berücksichtigung lateraler Bewegungen beschränkt. Um die Genauigkeit der Vorhersage zu erhöhen, werden neben Umgebungssensorikdaten auch Informationen herangezogen, die durch V2V- und V2I-Technologien übermittelt werden. Auf Basis der ermittelten Sequenz von longitudinalen Geschwindigkeitswerten des vorausfahrenden Fahrzeugs kann dessen Positionierung in Längsrichtung für jeden Zeitschritt des betrachteten Zeitraums bestimmt werden.
In jüngster Vergangenheit wurden zahlreiche Studien veröffentlicht, die die Anwendbarkeit künstlicher neuronaler Netze zur Prädiktion von Trajektorien untersuchen [1], [31], [32], [33], [34], [35]. Eine häufig adressierte Problemstellung ist die Vorhersage einer kontinuierlichen Fahrtrajektorie unter Berücksichtigung möglicher Interaktionen mit umgebenden Fahrzeugen im Autobahnszenario. Ein Ansatz umfasst die Verwendung von LSTM-Encoder-Decoder-Modellen [32], [34], [35]. Die Ausgaben dieser Modelle bestehen nicht aus diskreten Fahrmanövern, sondern aus kontinuierlichen, räumlichen Koordinaten der prädizierten Trajektorien für den folgenden Zeitrahmen von einigen Sekunden. Als Alternative wurden auch geschichtete RNN-Netzwerkstrukturen verwendet. Unter Einbezug der bisherigen Fahrstrecke des Egofahrzeugs und der umgebenden Verkehrsteilnehmer, sowie weiteren Informationen, wie beispielsweise der jeweilige Zeitabstand, konnte die longitudinale und laterale Trajektorie eines Egofahrzeugs für einen Zeithorizont von bis zu zehn Sekunden mit vielversprechender Genauigkeit ermittelt werden [31], [33].
In weiteren Publikationen wurden die Möglichkeiten zur Vorhersage in Bezug auf die Fahrtrajektorie in spezifischen Szenarien, darunter auch im städtischen Raum, betrachtet. In [36] wurden Fahrstrei-

fenwechseltrajektorien mithilfe eines LSTM-Netzes in Form von kontinuierlichen longitudinalen und lateralen Positionsangaben für einen Zeithorizont von fünf Sekunden vorhergesagt. Hierfür wurden dem Modell der aktuelle Umgebungszustand und die Fahrtrajektorien vorheriger Zeitschritte zugeführt. In [37] wurden ebenfalls mittels eines LSTM-basierten Prädiktionsmodells die zukünftigen Trajektorien umgebender Fahrzeuge an mehrspurigen Kreuzungen bestimmt. Als Ein- und Ausgaben des Modells wurden die Geschwindigkeit, der zum Egofahrzeug relative Winkelversatz, sowie der relative longitudinale und laterale Abstand des benachbarten Fahrzeugs aus realen Sensordaten verwendet.
Die Möglichkeiten zur Prädiktion von Trajektorien wurden in zahlreichen Studien mit unterschiedlichen Ansätzen untersucht. Mittels des MLs, insbesondere LSTM-Netzwerken, wurden in den beschriebenen Studien vielversprechende Ergebnisse erzielt. Ein gemeinsames Merkmal all dieser Ansätze ist, dass deren Erfolgsaussichten für möglichst genaue Prädiktionen in erheblichem Maße auf den verfügbaren Trainingsdaten beruhen.

2.3 Optimierung der longitudinalen Fahrzeugführung

Die Entwicklung von Fahrerassistenzsystemen hat im Laufe der letzten Jahrzehnte bedeutende Fortschritte verzeichnet, unter anderem in der Weiterentwicklung energieeffizienter longitudinaler Fahrzeugführung. Die Verbesserung der Energieeffizienz vernetzter, automatisierter Fahrzeuge umfasst Aspekte wie die Antizipation der Straßenzustände, der Schaltlogik von LSA, des Fahrzeugfolgeverhaltens und Fahrstreifenwechsels [38].
Die Antizipation des Straßenzustandes ermöglicht eine energieeffiziente Geschwindigkeitsanpassung durch Vorkenntnis über kommende Geschwindigkeitsbegrenzungen oder geometrische Gegebenheiten der Straße, wie Kurven oder Steigungen [39]. Die Antizipation der Schaltlogik von LSA ermöglicht ein energieeffizientes Anfahren der jeweiligen Kreuzung, wodurch Kraftstoffeinsparungen von über 5 % bei Fahrten im urbanen Raum festgestellt werden können [40], [41], [42]. Antizipatives Fahrzeugverhalten und Fahrstreifenwechsel können durch die Kenntnis über die umgebenden Fahrzeuge zur Energieoptimierung beitragen. Mithilfe der Vorhersage des longitudinalen Fahrverhaltens des vorausfahrenden Fahrzeugs kann das Egofahrzeug die Geschwindigkeit energieoptimal anpassen [43], [44]. Weitere Energieeinsparpotenziale können durch eine frühzeitige Anpassung der eigenen Geschwindigkeit an die Fahrweise eines in den eigenen Fahrstreifen einscherenden Verkehrsteilnehmers erzielt werden [45]. Darüber hinaus kann in bestimmten Situationen der Energiebedarf des Egofahrzeuges durch das Initiieren eines eigenen Fahrstreifenwechsels optimiert werden [46].
Die Fortschritte bei der Entwicklung zuverlässiger und stabiler V2X-Kommunikationstechnologien bereiten den Weg für kooperative Fahrfunktionen, welche ein weiterführendes Potenzial zur Energieeinsparung aufweisen. Historisch betrachtet fokussierte sich die Forschung in diesem Bereich über mehrere Jahrzehnte auf die Lastkraftwagen (Lkw) - Kolonne (engl. Platoon) auf Autobahnen [47], [48], [49], [50], [51], [52]. Durch kontinuierlichen Datenaustausch können Lkw mit geringem Abstand hintereinander fahren, um den aerodynamischen Widerstand und dadurch den Gesamtkraftstoffverbrauch zu reduzieren. Allerdings stellt das zunehmende Verkehrsaufkommen und die damit verbun-

denen komplexen Verkehrssituationen eine erhebliche Herausforderung für die Umsetzung von kooperativem Fahren in städtischen Gebieten dar. Insbesondere die dynamischen Verkehrssituationen erfordern eine zuverlässige Koordination von Fahrmanövern. Die nachfolgenden Abschnitte werden einen Überblick über den Stand der Technik im Bereich kooperativer Fahrfunktionen geben und auf das Fahrmanövermanagement im städtischen Gebiet eingehen.

2.3.1 Kooperative Fahrfunktionen

Mehrere Forschungsprojekte haben bereits Konzepte und Untersuchungen zum kooperativen Fahren in städtischen Bereichen vorgestellt. Im Projekt MAVEN [53] wurde die dynamische Geschwindigkeitsregelung von vernetzten Fahrzeugen in urbanen Umgebung untersucht. Innovative Methoden zur Initialisierung, Zusammenführung, zum Verlassen und zur Aufteilung von Fahrzeugkolonnen wurden diskutiert. Sethuraman et al. führten im Projekt DART Untersuchungen zur Geschwindigkeitsregelung vernetzter Busse in städtischen Bereichen hinsichtlich Verkehrssteuerung und Energiebedarf durch. Simulationsergebnisse zeigten zusätzliches Energieeinsparpotenzial durch Priorisierung von Verkehrssignalen für die Buskolonnen [54]. Beide Forschungsprojekte zeigten eine Möglichkeit des kooperativen Fahrens in urbanen Bereichen.
Verschiedene Ansätze wurden für das kooperatives Fahren vorgeschlagen, diese unterteilen sich hauptsächlich in verteilte und zentralisierte Ansätze. Bei verteilten Regelungsstrategien besitzt jedes Fahrzeug in einer Kolonne einen eigenen Regelungsalgorithmus und kommuniziert direkt mit den eigenen vorausfahrenden Fahrzeug, während bei zentralisierten Regelungsstrategien die Zustände aller Fahrzeuge durch einen zentralen Regelungsalgorithmus auf einem der Fahrzeug in einer Kolonne oder in der Cloud gesteuert werden. [55]
Die am häufigsten untersuchte Methode für kooperative Fahrfunktionen basiert auf einer verteilten Regelungsstrategie. Ein robuster und verteilter PID-ähnlicher Regelungsansatz kann zur kooperativen Führung von heterogenen, nicht linearen, vernetzten und autonomen Fahrzeugen verwendet werden und anhand der statischen Rückmeldung des Systems können die Koeffizienten des Reglers mittels der Lyapunov-Theorie angepasst werden. Dadurch ist die analytische Stabilität der Kolonne gewährleistet und die Koordination sowie Steuerung von Multi-Agenten-Systemen in kooperativen Fahrszenarien verbessert. [56], [57], [58], [59]
Mithilfe eines verteilten H_∞-Regelungsansatzes können die Unsicherheit der Fahrzeugdynamik, externe Störungen sowie nicht-ideale Eigenschaften der drahtlosen Kommunikation berücksichtigt und durch die Statusrückmeldung kompensiert werden, somit sind die Stabilität und Verfolgungsfähigkeit einer Kolonne gewährleistet [60].
Bei einer verteilten modellprädiktiven Regelung (MPR) wurden der Kraftstoffverbrauch und die Manöverkoordination in die Zielfunktion einbezogen, während der Fahrgastkomfort und die Fahrzeugsicherheit in der Systemlimitierung berücksichtigt wurden [61], [62], [63], [64]. Diese Methode kann mit einem stochastischen Fahrerverhaltensmodell, welches durch einen stochastischen inversen bestärkenden Lernalgorithmus (engl. stochastic inverse reinforcement learning) erlernt wird, erweitert werden [65].
Reinforcement Learning (RL) Methode wurde ebenfalls für die Regelungsaufgabe und zur Verbesse-

rung der Effizienz von Fahrzeugkolonnen verwendet. Der Platoon Sharing Deep Deterministic Policy Gradient Algorithmus (PSDDPG) überwindet das Problem des ineffizienten Explorierens von kontinuierlichen Aktionsräumen und ermöglicht somit eine verbesserte Kontrolle der Fahrzeugkolonnen sowie das Potenzial zur Reduktion des Energiebedarfs und zur Verbesserung der Verkehrseffizienz. [66], [67]

Viele Veröffentlichungen konzentrieren sich lediglich auf die Kolonnenstabilität, jedoch wurde ebenso ein Energieeinsparpotenzial von 3 bis 10 % in verschiedenen Fahrszenarien festgestellt [62], [63]. Die verteilten Regelungsalgorithmen sind robust gegenüber Kommunikationsunsicherheiten und daher weit verbreitet. Allerdings stellt eine verteilte Regelungsstrategie eine lokale Optimierung dar. Jedes Fahrzeug in einer Kolonne bestimmt die eigene energieeffiziente Fahrtrajektorie und somit bleiben die Koordination der Kolonne, abhängig von der Verkehrslage, und die Durchführung unterschiedlicher Fahrmanöver eine Herausforderung. Darüber hinaus muss jedes Fahrzeug in einer Kolonne die Informationen von dessen eigenen vorausfahrenden Fahrzeug generieren. Die Auswirkungen des Prädiktionsfehlers auf jedes Fahrzeug sind gleich und können nicht durch ganzheitliche Optimierung kompensiert werden.

Im Vergleich zur verteilten Regelungsstrategie bietet ein zentralisierter Ansatz den Vorteil, dass die Interaktion zwischen Fahrzeugen in einem Optimierungsproblem berücksichtigt und weitere Verkehrsteilnehmer für die Koordination des Fahrmanövers integriert werden können.

In der wissenschaftlichen Literatur wurde bereits ein robuster zentralisierter modellprädiktiver Regelalgorithmus vorgestellt [68], [69], [70]. Im Rahmen dieses Ansatzes erfasst der Kolonnenführer die Zustandsdaten der nachfolgenden Fahrzeuge, berechnet die optimalen Beschleunigungswerte für alle Kolonnenfahrzeuge und übermittelt diese an die jeweiligen nachfolgenden Fahrzeuge. Simulationsergebnisse weisen darauf hin, dass die entwickelte Regelungsstrategie in der Lage ist, die Stabilität gegenüber Modellunsicherheiten sowie externen Störungen zu gewährleisten. In den genannten Publikationen wurde allerdings keine eingehende Analyse des Energiebedarfs unter Berücksichtigung realitätsnaher Fahrszenarien durchgeführt. Darüber hinaus beschränkte sich die Untersuchung der Leistungsfähigkeit der Regelungsstrategie auf isolierte Fahrszenarien, wie beispielsweise während einer Beschleunigungs- oder Verzögerungsphase. Ein weiterer zentralisierter modellprädiktiver Regelalgorithmus zeichnet sich durch die Fähigkeit aus, menschliche Fahrer temporär in den Regelungsprozess zu integrieren [71]. Zusätzlich kann die Folgefahrtfunktion der nachfolgenden Fahrzeuge durch eine Speicherfunktion der über die V2V-Kommunikation übermittelten prädizierten Beschleunigungen des vorausfahrenden Fahrzeugs auch bei temporären Kommunikationsausfällen oder -unterbrechungen aufrechterhalten werden [72], [73]. Der Fokus dieser Forschung lag allerdings ausschließlich auf der Analyse der Kolonnenstabilität, während die Bewertung des Energiebedarfs und der Robustheit des Regelalgorithmus nicht berücksichtigt wurden.

Ein datengetriebener Ansatz stellt eine weitere vielversprechende Alternative zur zentralisierten modellprädiktiven Regelung für Fahrzeugkolonnen dar. Die Anwendung von Methoden des RLs eröffnet Perspektiven für die Verbesserung der Stabilität automatisierter Fahrzeugkolonnen und die Integration menschengesteuerter Fahrzeuge in die Regelungsalgorithmen [74]. Diese Verfahren können die optimale Regelgrößen für sämtliche Kolonnenfahrzeuge ermitteln, unabhängig von der Kenntnis der

dynamischen Parameter des Systems. Dies wurde durch simulative Fallstudien bestätigt, in denen die Kolonnenstabilität annähernd dem Niveau eines optimierungsbasierten Ansatzes entspricht. Des Weiteren wurden Verbesserungen in der Verkehrseffizienz sowie Energieeinsparungen von bis zu 8 % erzielt. [75], [76], [77], [78] Trotz der vielversprechenden Leistungsfähigkeit bergen datengetriebene Algorithmen jedoch auch Herausforderungen, insbesondere hinsichtlich der Gewährleistung von Sicherheit. Beispielsweise müssen fehlerhafte Regelungsbefehle, die durch diese Algorithmen verursacht werden könnten, durch Sicherheitsmechanismen abgefangen werden. Darüber hinaus erfordert die Erstellung umfangreicher und realistischer Datensätze für das Training dieser Algorithmen einen erheblichen Aufwand. Angesichts des aktuellen Entwicklungsstandes der V2X-Kommunikationstechnologie ist die praktische Umsetzung komplex und potenziell unzugänglich.
Die zuvor diskutierten zentralisierten Regelungsansätze für Fahrzeugkolonnen haben zwar bedeutende Fortschritte in der Regelung und Koordination von Fahrzeugkolonnen dargestellt, jedoch bleibt eine systematische Auswertung in Bezug auf die Fähigkeit zur Verbesserung des Energiebedarfs und Verkehrsflusses weitgehend unerforscht. Die Analyse der Leistungsfähigkeit der Regelungsstrategien wurde überwiegend auf der Beschleunigungs- und Verzögerungsphasen begrenzt, während realistische Fahrszenarien vernachlässigt wurden. Insbesondere wurden Aspekte wie die Störwirkung der umgebenden Verkehrsteilnehmer auf das Regelverhalten oder der Einfluss der Regelungsstrategie auf den allgemeinen Verkehrsfluss nicht systematisch untersucht. Diese mangelnde ganzheitliche Betrachtung unterstreicht die Notwendigkeit einer Integration von kooperativen Fahrfunktionen mit dem Fahrmanövermanagement, um ein umfassenderes Verständnis der Dynamik und Interaktionen innerhalb einer Fahrzeugkolonne und deren Umgebung zu erlangen.

2.3.2 Kooperatives Fahrmanövermanagement

Die Dynamik des städtischen Verkehrs verlangt eine Erweiterung der Fahrzeugführung einer Kolonne um diverse Manöver, welche die komplexe Koordination und das Zusammenspiel innerhalb einer Fahrzeugkolonne sowie mit anderen Verkehrsteilnehmern berücksichtigen. In städtischen Bereichen können vier unterschiedliche Fahrmanöver definiert werden [79], [80]: Aufschließ-, Einscher-, Ausscher- und Aufteilungsmanöver.
In der Forschung zur Koordination von Fahrmanövern wurden vielfältige Ansätze entwickelt. Regelbasierte Strategien für das Management von Fahrmanövern nutzen Geschwindigkeits- und Positionsdaten der an den Manövern beteiligten Fahrzeugen, um die longitudinale und laterale Fahrzeugführung während aufschließender und einscherender Fahrmanöver zu ermöglichen [81], [82], [83]. Im Gegensatz dazu legen optimierungsbasierte Ansätze energieeffizientere Fahrzeugtrajektorien für die Fahrzeuge fest, die in die Fahrmanöver involviert sind.
In diesem Kontext stellt die MPR eine wichtige Methode zur Koordination von Aufschließ-, Einscher- und Aufteilungsmanövern dar. In Kombination mit einem linearen quadratischen Regler (LQR), ermöglicht ein verteilter MPR-Algorithmus eine Verringerung des Abstands zwischen dem aufschließenden Fahrzeug und der Kolonne sowie eine Erhöhung des Abstands zwischen den Fahrzeugen in einer Kolonne zur Durchführung von Einscher-Manövern [84], [85]. Simulationsergebnisse zeigen, dass ein verteilter MPR-Algorithmus ein verbessertes Verhalten bei den Abstands- und Geschwindigkeitsfeh-

lern sowie eine kürzere Zeit für die Durchführung des Aufschließ- und Aufteilungsmanöver aufweist. Weiterführend ermöglicht der in [86] beschriebene MPR-Algorithmus das Beitreten mehrerer Fahrzeuge zu einer existierenden Kolonne. Die Fähigkeit, Manöver im Voraus zu planen, ermöglicht ein verbessertes Folgeverhalten.
Wenn die Information der vorausliegenden LSA in dem Regelungsalgorithmus berücksichtig wird, lässt sich die Fahrstrategie einer Kolonne entsprechend anpassen. Dabei kann die Kolonne in Abhängigkeit der LSA-Schaltzeit aufgeteilt werden, sodass eine maximale Anzahl von Fahrzeugen für jede Grünphase der LSA die Kreuzung passieren kann. Des Weiteren kann die Fahrtrajektorie aller beteiligten Fahrzeuge optimiert werden. Simulationsergebnisse zeigen, dass durch diesen Ansatz eine Energieeinsparung von bis zu 59 % und eine Reduktion der Reisezeit um 2 % realisierbar sind. Dabei können bis zu 100 Fahrzeuge bei der Aufteilung berücksichtigt werden [87], [88], [89], [90].
Neben den optimierungsbasierten Ansätzen ermöglichen datengetriebene Methoden, wie generische Algorithmen oder RL, die Koordination von Fahrmanövern. Beispielsweise wurde in [91] ein RL-basierter Ansatz eingesetzt, um das optimale Fahrverhalten in einem Szenario zu bestimmen, in dem eine Fahrzeugkolonne in eine zweite Kolonne einschert. Die numerischen Simulationsergebnisse dieser Studie zeigen, dass der vorgeschlagene Ansatz in der Lage ist, den Energiebedarf um bis zu 76,7 % zu reduzieren und den durchschnittlichen Ruck um bis zu 50 % zu verringern, indem lediglich das kooperative Verhalten während der Zusammenführung optimiert wird.
Darüber hinaus wurden RL-Methoden auch für die Steuerung von Fahrzeugen an signalisierten Kreuzungen untersucht, wobei das Ziel darin besteht, den Verkehrsfluss zu maximieren und den Energiebedarf zu reduzieren. Durch die Integration von Informationen über vorausliegende LSA in den Regelungsalgorithmus können Fahrstrategien entwickelt werden, die eine frühzeitige Aufteilung der Fahrzeugkolonne ermöglichen. Der RL kann sowohl zur Entscheidungsfindung über die Position der Aufteilung als auch zur Planung von Fahrtrajektorien eingesetzt werden [92], [93], [94]. Des Weiteren wurde in [95] ein generischer Algorithmus vorgestellt, der die optimale Anpassung der Anzahl von Fahrzeugen in einer Kolonne an die Schaltzeit der LSA ermöglicht und Fahrzeuge, die die Kreuzung nicht während derselben grünen Phase passieren können, von der Kolonne entfernt. Die Simulationsergebnisse deuten darauf hin, dass dieses Verfahren das Potenzial hat, den Energiebedarf um bis zu 20 % und gleichzeitig die Fahrzeit um bis zu 30 % zu reduzieren.
In dem vorliegenden Kapitel wurde festgestellt, dass bereits unterschiedliche Konzepte zur Umgebungserfassung, Trajektorienprädiktion der umgebenden Fahrzeugen und Optimierung der longitudinalen Fahrzeugführung evaluiert wurden. Basierend auf den beschriebenen Studien wird in dieser Dissertationsschrift eine detaillierte Simulationsumgebung aufgebaut, welche es ermöglicht, Daten aus der Verkehrsumgebung präzise zu erfassen. Durch den Einsatz von LSTM-Netzwerke werden zwei Prädiktionsmodelle für das Voraussagen der Fahrtrajektorien der umgebenden Verkehrsteilnehmer entwickelt. Ein zentralisierter Ansatz wird für die Entwicklung prädiktiver und kooperativer Fahrzeugfunktion inklusive der Fahrzeugführung und des Fahrmanövermanagements verwendet. Die Implementierung und Evaluierung der kooperativen Fahrfunktionen erfolgt mittels einer Co-Simulationsplattform, deren Konzeption und Funktionsweise im folgenden Kapitel eingehend erläutert wird.

3 Konzeption der Co-Simulationsplattform

Basierend auf der in Abbildung 2.1 dargestellten Funktionsstruktur der kooperativen Fahrfunktionen besteht die Co-Simulationsplattform aus drei Hauptkomponenten: die Verkehrs- und Fahrzeugsimulation, dem kooperativen Fahrmanövermanagement sowie den kooperativen Fahrfunktionen. Der vollständige Aufbau der Co-Simulationsplattform mit den Verbindungen zwischen den einzelnen Hauptkomponenten ist in Abbildung 3.1 veranschaulicht.

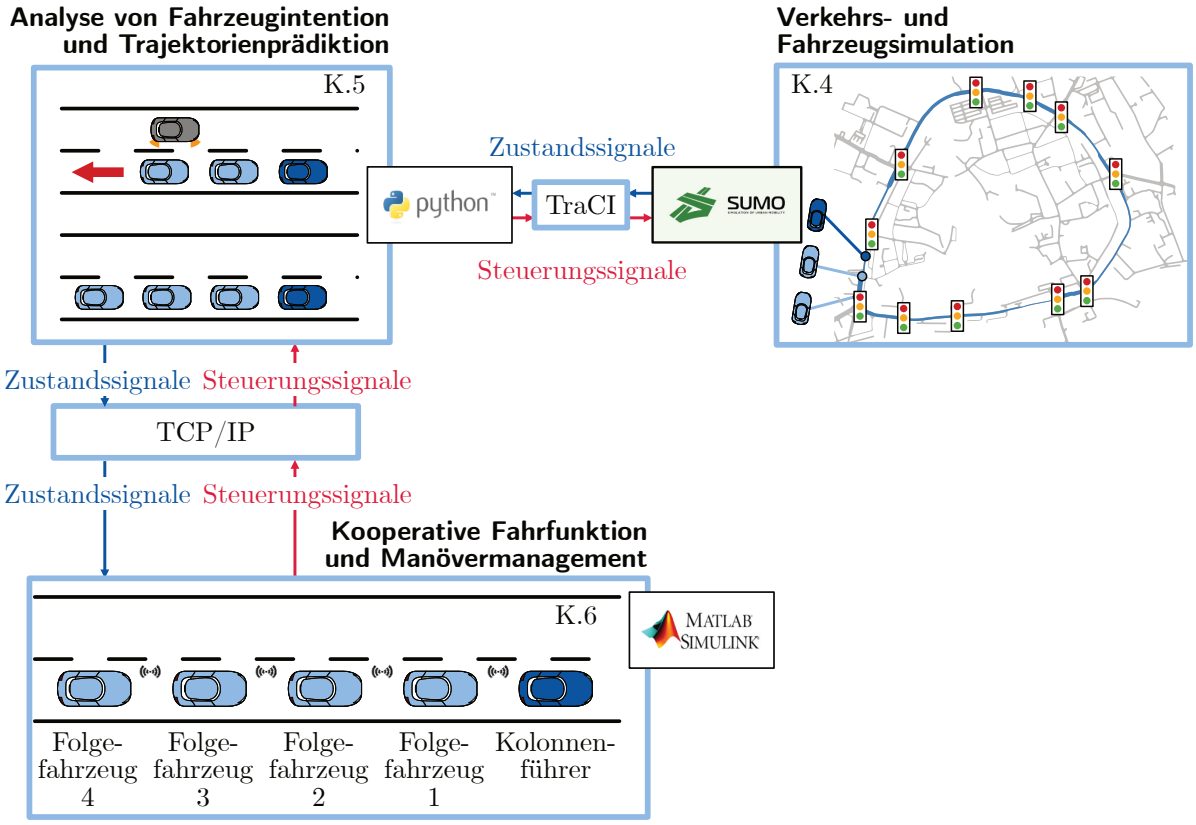

Abbildung 3.1: Strukturbild der Fahrzeug- und Verkehrs-Co-Simulationsplattform

In Kapitel 4 wird die Verkehrs- und Fahrzeugsimulation in der Software Simulation of Urban MObility (SUMO) implementiert. Die Anbindung der realistischen Verkehrssimulation an dem kooperativen Fahrmanövermanagement erfolgt über die Schnittstellenfunktion des Traffic Control Interface (TraCI), welche den Zugriff auf die Straßenverkehrsimulation ermöglicht und erlaubt, Werte von simulierten Objekten abzurufen und zu modifizieren.

In Python werden die Fahrzeugintention analysiert und ein Kommunikationsmodul etabliert. Letzteres dient vorrangig der Herstellung einer Datenverbindung zwischen MATLAB/Simulink und SUMO. Mithilfe von TraCI können die aktuellen Zustandssignale, wie z. B. die aktuelle Geschwindigkeit und Beschleunigung, die zurückgelegte Strecke aller Fahrzeuge in der Verkehrssimulation, in Python empfangen werden. Die Daten werden daraufhin ausgewertet, sodass die Fahrzeugintention überprüft und Fahrmanöver, wie z. B. Einscheren, erkannt werden können. Über eine TCP/IP-Schnittstelle werden die vorbereiteten Datenpakete den kooperativen Fahrfunktionen in MATLAB/Simulink zugeführt. In umgekehrter Richtung empfängt das Kommunikationsmodul die Steuerungssignale, wie z. B. Be-

schleunigungsanforderungen aller Kolonnenfahrzeuge sowie die Genehmigungen von Fahrmanövern, von der kooperativen Fahrfunktion über TCP/IP. Im Anschluss erfolgt eine Aufbereitung der Daten, damit diese über TraCI als Steuerungssignale an die Fahrzeuge in SUMO weitergeleitet werden.
In Kapitel 5 werden ebenfalls in Python die Trajektorienprädiktion der benachbarten Fahrzeuge implementiert. Um das Verhalten der umliegenden Verkehrsteilnehmer besser zu beurteilen und in die Regelung einzubinden, werden zwei Prädiktionsmodelle eingesetzt: eines für das vorausfahrende Fahrzeug (VF) und eines für das nicht-automatisierte Fahrzeug (NAF). Die Geschwindigkeiten des VFs werden direkt in MATLAB/Simulink auf Basis der empfangenen Zustandssignale prädiziert. Die Geschwindigkeit eines NAFs auf dem nebenliegenden Fahrstreifen wird mithilfe eines in Python umgesetzten Prädiktionsmodell vorhergesagt und wiederum durch TCP/IP an die kooperative Fahrfunktionen weitergeleitet.
Das Kernelement der Co-Simulationsplattform ist die in MATLAB/Simulink implementierte kooperative Fahrfunktion in Kapitel 6, welche die Überprüfung der Bedingungen zur Genehmigung der Fahrmanöver und die zentralisierte Kolonnenregelung beinhalten. In Abhängigkeit der Verkehrssituation und mithilfe der Vorbereitung der Daten in Python, können Fahrmanöver durchgeführt und eine energieeffiziente Fahrt der Kolonnenfahrzeuge gewährleistet werden. Durch die Anbindung an die Verkehrssimulation SUMO kann die kooperative Fahrfunktion anhand der simulierten Fahrzeuge in realitätsnahen Verkehrsszenarien validiert werden. Dies ist insbesondere von Interesse, da hierdurch die Koexistenz zentralisiert-geregelter Kolonnenfahrzeuge, automatisierter und nicht-automatisierter Verkehrsteilnehmer im selben Verkehrsraum untersucht werden kann. Die Co-Simulationsplattform bietet ebenfalls den Vorteil, im Gegensatz zu herkömmlichen Untersuchungen, die meist auf ein einzelnes, spezifisches Fahrszenario basieren, dass durch die Verwendung von SUMO eine Vielzahl zufälliger Fahrszenarien erstellt werden kann. In diesen Szenarien können Fahrmanöver automatisch im fließenden Verkehr durchgeführt werden. Dabei können sowohl freie als auch gebundene Verkehrsszenarien berücksichtigt werden. Nach einer ausreichenden Anzahl von Simulationen mit unterschiedlichen zufälligen Verkehrsszenarien kann eine makroskopische Auswertung des gesamten Verkehrsgeschehens vorgenommen werden.
Ein weiterer Vorteil der Co-Simulationsplattform besteht darin, dass in SUMO mehrere realitätsnahe elektrische Fahrzeugmodelle zur Verfügung stehen. Anders als bei herkömmlichen Simulationsansätzen können nahezu beliebig viele Fahrzeuge in der Simulation berücksichtigt werden. Auch die Anzahl der Fahrzeuge, die von der Kolonne aufgenommen werden können, ist nicht begrenzt und ergibt sich durch die zufällig generierten Verkehrsszenarien. Dies ermöglicht eine umfassende Untersuchung des Energiebedarfs nicht nur von Kolonnenfahrzeugen, sondern auch von allen anderen Fahrzeugen in der Simulation.
Zur Untersuchung des Energiebedarfs von Kolonnenfahrzeugen steht eine Vielzahl an modernen Fahrermodellen in SUMO zur Verfügung. Eine vielversprechende Referenzfahrstrategie ist das Intelligent Driver Model (IDM). Hierdurch kann das prozentuale Energieeinsparpotenzial der zentralisierten Kolonnenregelung im Vergleich zu der Referenzstrategie ausgewertet werden.
In Anbetracht der genannten Vorteile erfolgt im anschließenden Kapitel zunächst die Erläuterung der Modellierung der Simulationsumgebung in SUMO.

4 Simulationsumgebung

Um die Auswirkungen kooperativer Fahrfunktionen auf den Energiebedarf und Verkehrsfluss zu untersuchen, ist eine realitätsnahe Testumgebung erforderlich, in der diese Funktionen unter bestimmten Annahmen, Voraussetzungen und Vereinfachungen getestet werden können. Eine wesentliche Voraussetzung für die Umsetzung kooperativer Fahrfunktionen ist eine stabile V2X-Kommunikation, die in der realen Welt noch nicht ohne Weiteres gewährleistet werden kann. In einer Simulationsumgebung hingegen können Daten von allen Verkehrsteilnehmern und der Infrastruktur mit geringerem Aufwand abgerufen werden, wodurch eine Validierung der kooperativen Fahrfunktionen ermöglicht wird.
Neben den Grundlagen zur Simulation eines Straßenverkehrssystems werden in den folgenden Abschnitten die relevanten Komponenten der Verkehrssimulation diskutiert. Hierzu gehören das Netz-, Verkehrsnachfrage- und Verhaltensmodell, die es ermöglichen, Straßennetze aufzubauen und einen stochastischen Verkehrsfluss einschließlich weiterer umgebenden Verkehrsteilnehmer und LSA realistisch abzubilden.
Zusätzlich zur Verkehrssimulation ist die Fahrzeugsimulation ein weiterer wichtiger Bestandteil für die energetische Untersuchung der kooperativen Fahrfunktionen, daher ist eine realistische Abbildung des Antriebsstrangs hierbei von großer Bedeutung. Im Anschluss an die Darstellung der Verkehrssimulation wird das Fahrzeugmodell im Detail erläutert und die gesamte Simulationsumgebung verifiziert.

4.1 Grundlagen zur Straßenverkehrssimulation

Eine Straßenverkehrssimulation muss sowohl das Verhalten der Verkehrsteilnehmer als auch die Funktionalität der Straßeninfrastruktur berücksichtigen. Dies erfordert umfassende Kenntnisse verschiedener Modelle und Methoden, die zur Modellierung des Verkehrsflusses und der Verkehrsinfrastruktur eingesetzt werden können.

4.1.1 Grundstruktur einer Verkehrssimulation

Gemäß der Darstellung von Detering [96] bildet das Simulationsmodell, welches sich aus den Netz-, Verhaltens- und Verkehrsnachfragemodellen zusammensetzt, die zentrale Komponente des Verkehrssimulationswerkzeugs. Mithilfe des Netzmodells können Straßennetzwerke einschließlich der Streckenverläufe, Kreuzungen, Einmündungen und LSA mit deren Schaltprogramm abgebildet werden. Das Verhaltensmodell umfasst das Fahrzeugfolge-, Fahrstreifenwechsel- und das Routenwahlmodell, die das Verhalten aller Fahrzeuge in der Verkehrssimulation beschreiben. Die Fahrzeugfolge- und Fahrstreifenwechselmodelle modellieren dabei jeweils die Längs- und Querdynamik einer Fahrer-Fahrzeug-Einheit (FFE) und ermöglichen dieser, einem vorausfahrenden Fahrzeug zu folgen und Fahrstreifenwechsel durchzuführen. Im Routenwahlmodell werden die Routen jeder FFE festgelegt, in dem ein Start- und Zielpunkt ausgewählt und die zu befahrenden Straßenabschnitte festgelegt

werden. Mittels des Routenwahlmodells kann das Verkehrsaufkommen im Verkehrsnachfragemodell bestimmt werden. Dabei können die Routen entweder während der Simulation dynamisch festgelegt oder statisch für ein einzelnes Fahrzeug vorgegeben werden. Zusätzlich zum Simulationsmodell als Kernkomponente des Verkehrssimulationswerkzeugs besteht die Möglichkeit, Daten zu importieren und zu exportieren sowie die Simulation zu visualisieren und auszuwerten. [96]
Zur Modellierung und Untersuchung des Verkehrs werden Verkehrskenngrößen definiert, welche im nachfolgenden Unterkapitel im Detail beschrieben werden.

4.1.2 Kenngrößen des Verkehrs

Die Verkehrskenngrößen werden gemäß [96], [97] in mikroskopische und makroskopische unterteilt. Die mikroskopischen Kenngrößen erfassen Eigenschaften von einzelnen Fahrzeugen, während die makroskopische Ebene die räumlichen, zeitlichen oder räumlich-zeitlichen Aggregationen der mikroskopischen Kenngrößen erfasst. Verkehrskenngrößen können sowohl lokal als auch als Momentanaufnahme auf beiden Ebenen ermittelt werden.
Die mikroskopischen Verkehrskenngrößen umfassen die charakteristischen Eigenschaften einzelner Fahrzeuge wie beispielsweise die momentane und lokale Geschwindigkeit $v_{\mathrm{m/l}}$, den Abstand d und Zeitabstand t_{d} zum vorausfahrenden Fahrzeug. Auf der makroskopischen Ebene können Verkehrskenngrößen wie die durchschnittliche Geschwindigkeit $\bar{v}_{\mathrm{m/l}}$, Verkehrsdichte ρ sowie Verkehrsstärke q bestimmt werden. [96], [97]
Die momentane Kenngröße der Verkehrsdichte ρ beschreibt die Anzahl an Fahrzeugen $n_{\rho,\mathrm{Fzg,ges}}$ auf einem Straßenabschnitt Δs zu einem Zeitpunkt:

$$\rho \;=\; \frac{n_{\rho,\mathrm{Fzg,ges}}}{\Delta s} \tag{4.1}$$

Die lokale Kenngröße der Verkehrsstärke q bezeichnet die Anzahl an Fahrzeugen $n_{\mathrm{q,Fzg,ges}}$, die während eines Zeitabschnitts Δt einen Straßenquerschnitt durchfahren.

$$q \;=\; \frac{n_{\mathrm{q,Fzg,ges}}}{\Delta t} \tag{4.2}$$

Die mittlere momentane Geschwindigkeit $\bar{v}_{\mathrm{m}}$ wird aus dem Verhältnis der Summe der zurückgelegten Strecke s_{m} innerhalb eines festen Zeitabschnitt Δt und Anzahl der gesamten Fahrzeuge $n_{\mathrm{Fzg,ges}}$ berechnet, und ist gleich dem Mittelwert der einzelnen momentanen Geschwindigkeiten v_{m}:

$$\bar{v}_{\mathrm{m}} \;=\; \frac{\sum_{n=1}^{n_{\mathrm{Fzg,ges}}} s_{\mathrm{m}}(n)}{n_{\mathrm{Fzg,ges}} \cdot \Delta t} = \frac{1}{n_{\mathrm{Fzg,ges}}} \cdot \sum_{n=1}^{n_{\mathrm{Fzg,ges}}} v_{\mathrm{m}}(n) \tag{4.3}$$

$$\text{mit } v_{\mathrm{m}} \;=\; \frac{s_{\mathrm{m}}}{\Delta t} \tag{4.4}$$

Die Korrelation zwischen Verkehrsdichte und -stärke kann ausschließlich unter der Annahme eines stationären Verkehrsflusses mithilfe der mittleren momentanen Geschwindigkeit hergestellt werden. Diese Annahme resultiert in einer Zustandsgleichung, welche in der wissenschaftlichen Literatur von [98] sowie [99] ausführlich diskutiert wird:

$$q = \bar{v}_{\mathrm{m}} \cdot \rho \tag{4.5}$$

Das Verhältnis zwischen Verkehrsstärke und Verkehrsdichte kann durch das Fundamentaldiagramm in Abbildung 4.1 grafisch dargestellt werden.

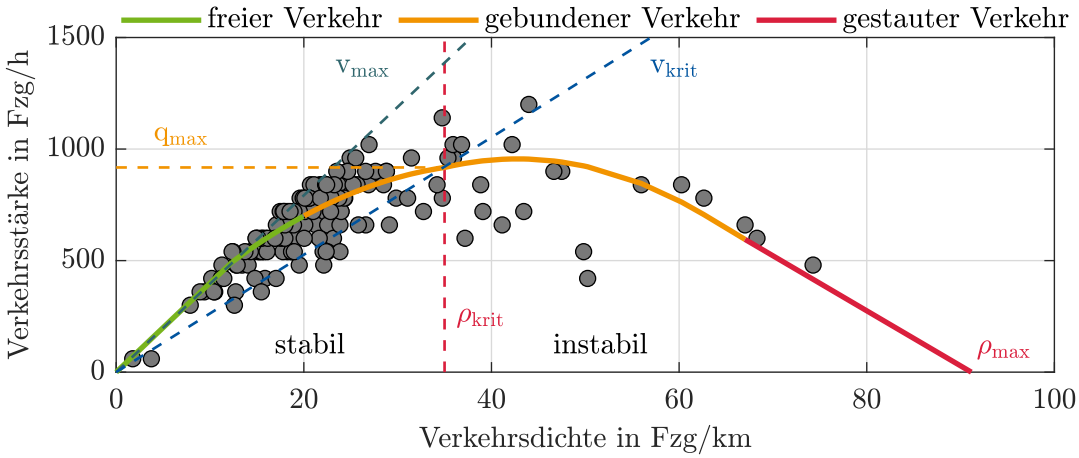

Abbildung 4.1: Fundamentaldiagramm nach [96], empirische Daten aus dem in 4.2 beschriebenen Simulationsszenario mit einer maximalen Anzahl von 200 Fahrzeugen

Gemäß [100] kann der Zusammenhang zwischen Verkehrsstärke, Verkehrsdichte und Wunschgeschwindigkeit, wie im Fundamentaldiagramm dargestellt, durch eine nicht-lineare, parabolische Funktion beschrieben werden:

$$q = v_{\max} \cdot \rho \cdot (1 - \frac{\rho}{\rho_{\max}}) \tag{4.6}$$

In der Abbildung 4.1 ist zu erkennen, dass bei geringen Verkehrsdichten die Verkehrsstärke annähernd linear mit der Verkehrsdichte ansteigt. $v_{\max}$ stellt die Wunschgeschwindigkeit im freien Verkehr dar, bei dem die Verkehrsteilnehmer deren Wunschgeschwindigkeit entsprechend den vorhandenen Gegebenheiten frei wählen können. Mit zunehmender Verkehrsdichte beeinflussen sich die Fahrzeuge gegenseitig und bilden erste Fahrzeuggruppen mit annähernd gleicher Geschwindigkeit. Die maximale Verkehrsstärke $q_{\max}$ wird bei einer kritischen Verkehrsdichte von ρ_{krit} erreicht, der Wert der mittleren momentanen Geschwindigkeit bei ρ_{krit} wird hierbei als kritische Geschwindigkeit v_{krit} bezeichnet. Eine weitere Zunahme der Verkehrsdichte führt zu einem instabilen Verkehrszustand und einem Übergang von gebundenem Verkehr zu gestautem Verkehr. Selbst geringfügige Störungen können zu Stauungen führen, bei denen der Verkehr zwischen Stehen, Fahren, Beschleunigen und Verzögern bei niedrigen Geschwindigkeiten wechselt. Bei einer Verkehrsdichte von $\rho_{\max}$ kommt es schließlich zum Stillstand des Verkehrs. [96], [98]

Basierend auf der Definition der Verkehrskenngrößen lassen sich die Modellierungsmethoden von Verkehrssimulationen im Wesentlichen in makroskopische, mikroskopische, mesoskopische und submikroskopische Modelle unterteilen [101]. Zur Untersuchung der Auswirkungen kooperativer Fahrfunktionen auf den Energiebedarf und den Verkehrsfluss werden mikroskopische Simulationsumgebungen verwendet, in denen jedes Fahrzeug und dessen Dynamik einzeln modelliert werden. Die makroskopischen Verkehrskenngrößen, wie in den vorherigen Abschnitten dargestellt, werden durch die Zusammenfassung und Analyse der Ergebnisse mikroskopischer Modelle ermittelt.

4.2 Modellierung des Verkehrssystems zur Untersuchung der kooperativen Fahrfunktionen

Für die Erforschung kooperativer Fahrfunktionen im urbanen Bereich ist die Identifizierung von repräsentativen innerstädtischen Fahrszenarien unerlässlich. Diese sollten eine Vielfalt von Verkehrsteilnehmern einschließen, wie beispielsweise Personenkraftwagen (PKW), Lastkraftwagen (LKW), Radfahrer, sowie Verkehrsinfrastruktur wie LSA, Kreuzungen und Einmündungen. Um eine realistische Abbildung des Verkehrs zu ermöglichen, sollte eine Fahrstrecke mit ausreichender Länge gewählt werden. Des Weiteren ist es für die Untersuchung des Fahrspurwechselverhaltens erforderlich, dass Straßen mit sowohl einer als auch mindestens zwei Fahrspuren entlang der Route vorhanden sind. Zusammenfassend können auf Basis eigener Erkenntnisse die folgenden Voraussetzungen für die Festlegung der Fahrroute für die Kolonnenfahrzeuge definiert werden:

- Die Geschwindigkeit sollte eine maximale Grenze von 50 km/h nicht überschreiten.
- Die Route sollte eine Länge von mindestens 10 km aufweisen.
- Die Route sollte ein- und zweispurige Straßen enthalten, wobei ein ausgewogenes Verhältnis von 50 % optimal ist.
- Zur Berücksichtigung realistischer Verkehrsbedingungen sollten auf der Route LSA vorhanden sein, deren Schaltprogramm entsprechend realitätsnah umgesetzt ist.

Im Rahmen der Forschungsprojekte HyNets[1] und HyNets4all[2] wurde in Zusammenarbeit mit der Universität Paderborn das Straßennetzwerk der Stadt Paderborn in der Software SUMO modelliert. Basierend auf den definierten Anforderungen wurde eine geeignete Fahrroute ausgewählt und in Abbildung 4.2 durch eine blaue Linie dargestellt.

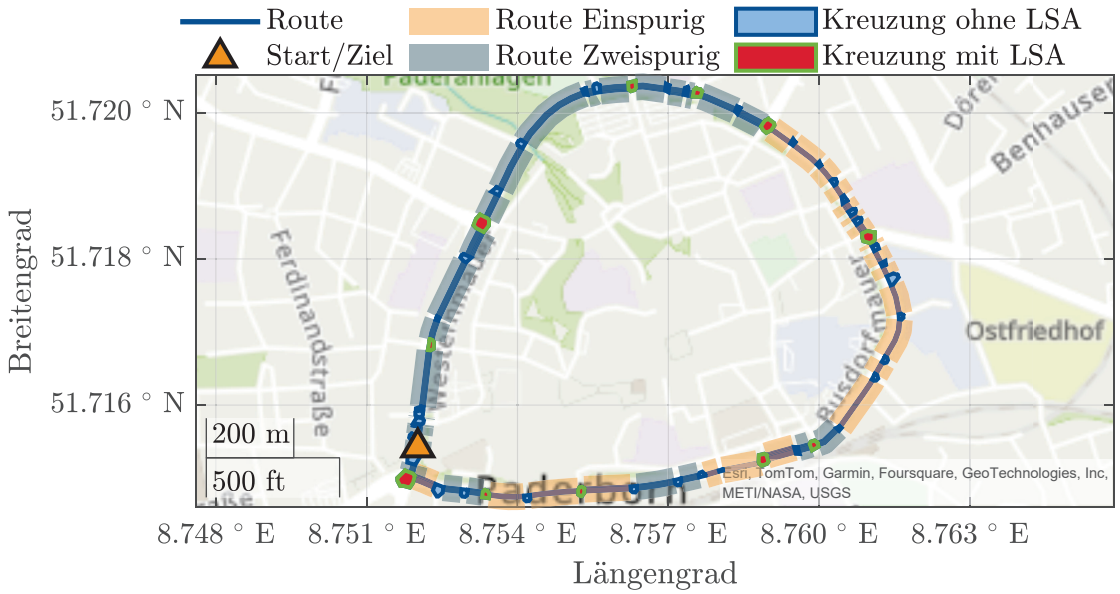

Abbildung 4.2: Auswahl der Fahrroute: Innerer Ring in der Paderborner Innenstadt

[1] Hy-Nets: Effiziente Hybridantriebe durch Fahrzeugkommunikation, gefördert durch Europäischer Fonds für regionale Entwicklung, EFRE.NRW

[2] Hy-Nets4all: Ganzheitliche Entwicklungs- und Validierungsumgebung zur Optimierung des elektrifizierten Fahrens im urbanen Raum, gefördert durch Europäischer Fonds für regionale Entwicklung, EFRE.NRW

Der Startpunkt der Route ist durch ein orangefarbenes Dreieck unten links gekennzeichnet, die Route verläuft im Uhrzeigersinn. Die Straßen auf der Route sind entweder einspurig in Gelb oder zweispurig in Dunkelgrün dargestellt. Die Gesamtlänge der Route beträgt ca. 3,22 km, wobei etwa 40 % der Strecke zweispurige Straßen sind, was ca. 1,35 km entspricht. Insgesamt gibt es auf der Route 11 Kreuzungen mit LSA und 34 Kreuzungen sowie Einmündungen ohne LSA. Alle Straßen auf der Route sind Vorfahrtstraßen. Die zulässige Höchstgeschwindigkeit beträgt 50 km/h. Der ringförmige Streckenverlauf ermöglicht es, die Streckenlänge beliebig zu verlängern, um die erforderliche Länge von 10 km zu erreichen. Daher wird die dargestellte Route viermal befahren, was zu einer Gesamtlänge von 12,88 km führt.
Das in Abbildung 4.2 präsentierte Straßennetzwerk, einschließlich der ausgewählten Fahrstrecke, wird im Verkehrssimulator SUMO modelliert. Eine ausführlichere Darstellung dieses Netzmodells wird im folgenden Abschnitt bereitgestellt.

4.2.1 Netzmodell

Zur Generierung des Straßennetzwerks in SUMO ist zunächst eine Erfassung der Straßenkarten erforderlich. Als Datenquelle zur Modellierung der Verkehrsszenarien wird das OpenStreetMap (OSM) verwendet, welches als die größte frei verfügbare Geodatenbank der Welt gilt [102].
Um die Straßengeometrie in SUMO abbilden zu können, muss die zuvor in einer OSM-Datei erfasste Straßenkarte zunächst in eine Netzdatei konvertiert werden. Im nächsten Schritt wird das konvertierte Straßennetzwerk im Netzwerkeditor Netedit von SUMO weiter bearbeitet. Abschließend kann das bearbeitete Straßennetzwerk für die Umgebungssimulation in SUMO verwendet werden. Zur Evaluierung kooperativer Fahrfunktionen werden realistische verkehrsbezogene Information im Straßennetzwerk gespeichert. Hierzu zählen unter anderem das Höhenprofil der einzelnen Straßenabschnitte, die Spuranzahl und -breite, die zulässige Höchstgeschwindigkeit sowie die Schaltprogramme der LSA. Die gewählte Fahrstrecke wird durch die Indexnummern aller relevanten Straßenabschnitte definiert und für Fahrzeuge freigegeben, welche durch kooperative Fahrfunktionen gesteuert werden. Die in vorangegangenen Schritten erstellte Fahrstrecke im aufgebauten Straßennetzwerk wird in der Abbildung 4.3 veranschaulicht.



Abbildung 4.3: Darstellung des Aufbaus von den gewählten Straßennetzwerk in SUMO

Da die ausgewählte Route der Fahrzeuge, die mit kooperativen Fahrfunktionen ausgestattet sind, nicht in dem Mittelbereich des inneren Rings liegt, werden zur Reduzierung der Rechenzeit diese Segmente aus dem Straßennetzwerk entfernt. Allerdings sind alle Kreuzungen und Verbindungspunkte so konzipiert, dass diese über Verbindungsstraßenabschnitte in jegliche Richtungen verfügen. Dies gewährleistet, dass ein in eine Kreuzung einfahrendes Fahrzeug potenziell in jede beliebige Richtung aus der Kreuzung herausfahren kann. Hierdurch wird eine Verkehrsbehinderung durch eine in die Kreuzung endende Route, die nicht über einen anschließenden Verbindungsstraßenabschnitt verfügt, effektiv vermieden.

4.2.2 Verhaltensmodell

Für eine realistische Darstellung des Verkehrsflusses ist es notwendig, weitere Fahrzeuge, die nicht mit kooperativen Fahrfunktionen ausgestattet sind, zu modellieren. Diese werden durch Fahrzeugfolge-, Fahrstreifenwechsel- und Routenwahlmodelle repräsentiert, welche in den nachstehenden Abschnitten näher erläutert werden.

Fahrzeugfolgemodell

Zur Modellierung eines realistischen longitudinalen Fahrerverhaltens wurden bereits verschiedene Fahrzeugfolgemodelle entwickelt und in SUMO implementiert. In [103] werden drei häufig verwendete Ansätze nach Wiedemann und Kaussen sowie das IDM hinsichtlich der Fähigkeit realistische Fahrtrajektorien abzubilden, evaluiert. Die Ergebnisse zeigen, dass das IDM im Durchschnitt am besten geeignet ist. Denn im Gegensatz zu den anderen Ansätzen basiert das IDM hauptsächlich auf dem Abstand zum vorausliegenden Objekt, welcher auch für menschliche Fahrer das wichtigste Kennwert ist und das Fahrverhalten beeinflusst.
Die durch das IDM errechnete Beschleunigung a ist eine Funktion aus der Geschwindigkeit v, dem Abstand d und der relativen Geschwindigkeit Δv zum vorausfahrenden Fahrzeug [104]:

$$a(v, d, \Delta v) = \dot{v}(v, d, \Delta v) = a_0 \left[\underbrace{1 - \left(\frac{v}{v_0} \right)^{\delta}}_{\text{Beschleunigung}} - \underbrace{\left(\frac{d^*(v, \Delta v)}{d} \right)^2}_{\text{Verzögerung}} \right] \tag{4.7}$$

Diese setzt sich aus einem Beschleunigungsterm auf einer freien Straße und einem Verzögerungsterm bei zu geringem Abstand zum vorausfahrenden Fahrzeug zusammen. Hierbei bezeichnet a_0 die maximale Wunschbeschleunigung und v_0 die Wunschgeschwindigkeit. Der Verzögerungsterm hängt von dem Verhältnis zwischen dem Wunschabstand d^* und dem tatsächlichen Abstand d ab, wobei der Wunschabstand folgendermaßen berechnet wird [104]:

$$d^*(v, \Delta v) = d_0 + T_0 v + \frac{v \Delta v}{2\sqrt{a_0 b_0}} \tag{4.8}$$

d_0 und T_0 beschreiben den minimalen Abstand und den Wunschzeitabstand für die Folgefahrt, während b_0 die maximale komfortable Verzögerung bezeichnet, die nur in sicherheitskritischen Situationen überschritten werden darf.

Die oben genannten Parameter können im in SUMO implementierten IDM-Fahrermodell eingestellt werden. Die Auswahl der Parameter basiert auf der Evaluierung von Referenzmessungen gemäß [105], wobei die ermittelten Mittelwerte aller generierten Parameter in Tabelle A.1.3 für die umliegenden automatisierten Pkw eingetragen sind. Die genaue Durchführung der Referenzmessungen und die Generierung der Parameter werden im Anhang A.1.1 beschrieben. Für die Zwecke dieser Arbeit wird angenommen, dass 85 % aller Fahrzeuge kommunikationsfähig sind und mit den in der Tabelle A.1.1 aufgeführten Parametern generiert werden, wodurch eine ausreichende Abdeckung des automatisierten Verkehrs zur Validierung der kooperativen Fahrfunktion gewährleistet werden kann. Für nicht-automatisierte Fahrzeuge, einschließlich Pkw, Motorräder und Lkw, wird eine separate Parametereinstellung verwendet. Die genaue Konfiguration und die Verteilung dieser Parameter sind in Tabelle A.1.2 im Anhang aufgeführt. Die Einstellungen für diese Fahrzeugkategorie wurden entsprechend deren spezifischen Merkmale und Verhaltensweisen, welche bereits in SUMO voreingestellt sind, festgelegt. Dadurch wird eine realistische Darstellung des nicht-automatisierten Verkehrs ermöglicht.

Fahrstreifenwechselmodell

Das Fahrstreifenwechselmodell beschreibt das situationsabhängige laterale Fahrverhalten und basiert im wesentlichen auf der Abfolge von logischen Verknüpfungen. Zur Abbildung des Lateralverhaltens werden der Wunsch und die Durchführbarkeit eines Fahrstreifenwechseln überprüft [106]. Basierend auf dem am häufigsten verwendeten Fahrstreifenwechelmodell nach Gipps, erfüllt das Standardmodell LC2013 in dem Verkehrssimulator SUMO zwei Hauptaufgaben [107]:

- Berechnung der Entscheidung zum Fahrstreifenwechsel auf Grundlage der Fahrzeugroute sowie der aktuellen und historischen Verkehrsbedingungen in dessen Umgebung.
- Berechnung der Geschwindigkeitsänderungen für das Egofahrzeug und für behindernde Fahrzeuge zur erfolgreichen Durchführung des gewünschten Fahrstreifenwechselmanövers.

Es werden vier verschiedene Motivationen unterschieden: regulatorische, strategische, kooperative und taktische Fahrstreifenwechsel. Der regulatorische Fahrstreifenwechsel ist durch gesetzliche Vorgaben, wie beispielsweise das Rechtsfahrgebot, definiert und dient der Einhaltung der Verkehrsregeln. Der strategische Fahrstreifenwechsel tritt auf, wenn ein Fahrzeug seine Fahrstreifen wechseln muss, um der vorgegebenen Route zu folgen. Beim kooperativen Fahrstreifenwechsel ermöglicht ein Fahrzeug den Spurwechsel anderer Verkehrsteilnehmer. Der taktische Fahrstreifenwechsel bezieht sich auf Manöver, bei denen ein Fahrzeug versucht, die Verfolgung eines langsamer fahrenden vorausfahrenden Fahrzeugs zu vermeiden. [107]
Die oben genannten Motivationen werden in einer hierarchischen Reihenfolge betrachtet und entsprechend ihrer Dringlichkeit behandelt. Wenn ein Fahrzeug einen dringenden strategischen Fahrstreifenwechsel benötigt, um seiner vorgegebenen Route zu folgen, wird dieser zuerst durchgeführt. Anschließend werden die Bedingungen für den regulatorischen, kooperativen und taktischen Fahrstreifenwechsel überprüft, zum Beispiel ob ein Fahrstreifenwechsel zu einer gefährlichen Situation

führen könnte oder ob ein Fahrzeug das Fahrstreifenwechseln eines anderen Fahrzeugs blockiert, welches einen dringenden strategischen Fahrstreifenwechsel wünscht.
Um eine realistischere Darstellung des Fahrstreifenwechsels zu erreichen, wird das Teil-Fahrstreifen (engl. Sublane)-Modell aktiviert, das es ermöglicht, einzelne Teilbereiche innerhalb einer Fahrspur zu unterscheiden und die genaue Position eines Fahrzeugs innerhalb eines Fahrstreifens detailliert zu beschreiben. Das Sublane-Modell trägt somit zur Steigerung der Realitätsnähe und Genauigkeit bei der Simulation von Fahrstreifenwechseln bei.
Durch die Aktivierung des Sublane-Modells wechselt das interne Fahrstreifenwechselmodell von SUMO vom Standardansatz LC2013 zum Modell SL2015. Dadurch eröffnen sich zahlreiche neue Möglichkeiten zur Anpassung und Individualisierung von Parametern. Beispielsweise können die Fahrzeuge kooperative Fahrstreifenwechsel initiieren, deren Geschwindigkeit entsprechend des Überholwunsches modulieren oder aus Ungeduld strategische Fahrstreifenwechsel vornehmen, um zügiger die ideale Fahrspur für die geplante Route zu erreichen. [108] In dieser Dissertationsschrift werden die standardmäßigen Parameter des Sublane - Modells in SUMO verwendet, um eine konsistente Vergleichbarkeit mit anderen Studien und Referenzwerten zu gewährleisten.

Routenwahlmodell

Das Routenwahlmodell definiert für sämtliche Fahrzeuge innerhalb der Verkehrssimulation Routen, welche sowohl den Start- als auch den Zielpunkt sowie die zu befahrenden Straßenabschnitte spezifizieren und unterscheidet zwischen einem statischen und einem dynamischen Modell. Im statischen Modell werden die Routenentscheidungen vor Beginn der Simulation einmalig festgelegt und bleiben während der gesamten Simulation unverändert. Im dynamischen Modell hingegen werden die Routenentscheidungen während der Simulation kontinuierlich aktualisiert, basierend auf aktuellen Informationen über den Verkehrszustand und mögliche Störungen. [96]
Im Verkehrssimulator SUMO können zufällige Routen für alle Fahrzeuge mithilfe der Funktion randomTrips vor der Simulation festgelegt werden. In dieser Dissertationsschrift wird das statische Routenwahlmodell verwendet, was bedeutet, dass alle umgebenden Fahrzeuge unter den gleichen Randbedingungen agieren und somit die Untersuchung und der Vergleich kooperativer Fahrfunktion mit unterschiedlichen Parametern ermöglicht wird.

4.2.3 Verkehrsnachfragemodell

Verkehrsnachfragemodelle erfassen die Anzahl der Ortsveränderungen, die die Verkehrsteilnehmer in einem Verkehrsnetz durchführen. Hierbei werden die Entscheidungsprozesse zur Ortsveränderung modelliert. Diese Entscheidungen umfassen die Auswahl von Aktivitäten, Zielen, Verkehrsmitteln, Abfahrtszeiten und Routen. [109] Durch das Verkehrsnachfragemodell wird das Verkehrsaufkommen in einem simulierten Straßennetz festgelegt. Unter Einbeziehung des Routenwahlmodells können die Verkehrsnachfragen in Form von Ursprung-Ziel-Matrizen (engl. Origin-Destination, O-D) definiert werden, bei denen lediglich der Start- und Zielpunkt festgelegt werden und die zu befahrenden Routen während der Simulation dynamisch bestimmt werden. [96]

In dieser Dissertationsschrift wird auf eine detaillierte Abbildung des Verkehrsnachfragemodells mithilfe der O-D-Matrix verzichtet. Der Grund dafür liegt darin, dass das ausgewählte Straßennetzwerk, wie im Abschnitt 4.2.1 beschrieben, nur einen begrenzten Teil der Stadt abdeckt und somit nicht in der Lage ist, die Komplexität des städtischen Verkehrs mit dessen vielfältigen Gründen für Ortsveränderungen vollständig abzubilden.
Um die kooperative Fahrfunktion in einer realistischen Verkehrssimulation mit variierendem Verkehrsaufkommen zu validieren, wird in dem Verkehrssimulator SUMO eine unterschiedliche Anzahl von Fahrzeugen in dem gleichen Straßennetz eingestellt. Im Abschnitt 4.4 erfolgt die Verifizierung der Verkehrssimulation mit unterschiedlicher Parametrierung.

4.3 Fahrzeugsimulation

Zur Bestimmung und Analyse des Energiebedarfs von Fahrzeugen mit kooperativer Fahrfunktion ist ein realistisches Verbrauchsmodell erforderlich. Koch et. al. entwickelten eine präzise physikalisch-basierte Modellierung des Energiebedarfs von batterieelektrischen Fahrzeugen, welche im Verkehrssimulator SUMO integriert wurde. [110]
Die Modellierung des batterieelektrischen Fahrzeugs erfolgt mithilfe eines Rückwärtsmodells, das die Betriebspunkte und Verluste aller Antriebsstrangkomponenten basierend auf den Traktionsmomenten eines Fahrzeugs zur Fortbewegung bestimmt. Dabei wird das Traktionsmoment M_{Trak} aus dem Produkt der Traktionskraft F_{Trak} und dem dynamischen Radhalbmesser r_{dyn} berechnet:

$$M_{\mathrm{Trak}} = F_{\mathrm{Trak}} \cdot r_{\mathrm{dyn}} = \left(m g f_{\mathrm{r}} \cos\alpha \; + \; m g \sin\alpha \; + \; \frac{\rho_{\mathrm{L}}}{2} c_{\mathrm{w}} A_{\mathrm{q}} v^2 \; + \; m e_{\mathrm{i}} a \right) \cdot r_{\mathrm{dyn}} \tag{4.9}$$

In der Berechnung werden verschiedene Widerstandsarten: der Rollwiderstand $m g f_{\mathrm{r}} \cos\alpha$, der Steigungswiderstand $m g \sin\alpha$, der Luftwiderstand $\frac{\rho_{\mathrm{L}}}{2} c_{\mathrm{w}} A_{\mathrm{q}} v^2$ und der Beschleunigungswiderstand $m e_{\mathrm{i}} a$ berücksichtigt.
Die Antriebsstrangkomponenten eines batterieelektrischen Fahrzeugs können anhand der in der Abbildung A.1.1 gezeigten schematischen Darstellung beschrieben werden. Hierbei beschreiben die grauen Pfeile die Reihenfolge und die Summierung bei der Rückwärtsberechnung der Batterieleistung.
Der Antriebsstrang besteht aus einer Hochvoltbatterie, welche die gesamte elektrische Energie für die Fahrzeugbewegung zur Verfügung stellt. Eine Leistungselektronik und ein Elektromotor wandeln die elektrische Energie in mechanische Energie um. Durch ein Getriebe wird die Übertragung der Drehzahl anhand der Übersetzungsstufe angepasst. Zusätzlich zur Traktionsleistung, die für die Fortbewegung des Fahrzeugs notwendig ist, wird Leistung für den Betrieb der Nebenverbraucher benötigt. Diese wird durch einen Gleichspannungswandler versorgt.
Durch die Anwendung des Rückwärtsmodells kann das Drehmoment des Elektromotors M_{EM}, basierend auf dem Traktionsmoment, dem Wirkungsgrad η_{G} und der Getriebeübersetzung i_{G} im motorischen und generatorischen Betrieb des Elektromotors, bestimmt werden (Gl. 4.10).

$$M_{\mathrm{EM}} = \begin{cases} M_{\mathrm{Trak}} \cdot {i_{\mathrm{G}}}^{-1} \cdot {\eta_{\mathrm{G}}}^{-1} & \text{motorischer Betrieb} \\ \max(M_{\mathrm{Trak}}, M_{\mathrm{Trak,min}}) \cdot {i_{\mathrm{G}}}^{-1} \cdot {\eta_{\mathrm{G}}}^{-1} & \text{generatorischer Betrieb} \end{cases} \tag{4.10}$$

Im generatorischen Betrieb setzt sich das Rekuperationsdrehmoment des Elektromotors aus dem Traktionsmoment M_{Trak} und dem minimalen Traktionsmoment $M_{\mathrm{Trak,min}}$ zusammen. Letzteres wird aus der negativen Drehmomentgrenze $M_{\mathrm{EM,min}}$, der Leistungsgrenze des Elektromotors $P_{\mathrm{EM,min}}$ sowie dem Übersetzungsverhältnis i_{G} und dem Wirkungsgrad η_{G} berechnet. Falls eine größere Verzögerung erforderlich ist, die allein durch die Rekuperation des Elektromotors nicht erreicht werden kann, wird zusätzlich ein Bremsmoment aus dem mechanischen Bremssystem benötigt.

$$M_{\mathrm{Trak,min}} = \max\left(\frac{M_{\mathrm{EM,min}} \cdot i_{\mathrm{G}}}{\eta_{\mathrm{G}}}, \frac{P_{\mathrm{EM,min}} \cdot r_{\mathrm{dyn}}}{\eta_{\mathrm{G}} \cdot v}\right) \tag{4.11}$$

Die Effizienz des Elektromotors und der Leistungselektronik wird basierend auf der mechanischen Leistung $P_{\mathrm{EM,mech}}$ und der Verlustleistung $P_{\mathrm{EM,verlust}}$ berechnet. Die Verlustleistung wird in Abhängigkeit von der Drehzahl und dem Drehmoment des Elektromotors n_{EM} und M_{EM} bestimmt (GL. 4.12).

$$\begin{aligned} P_{\mathrm{EM,el}} &= P_{\mathrm{EM,mech}} + P_{\mathrm{EM,verlust}} \\ P_{\mathrm{EM,verlust}} &= f(n_{\mathrm{EM}}, M_{\mathrm{EM}}) \end{aligned} \tag{4.12}$$

Die elektrische Leistung der Hochvoltbatterie $P_{\mathrm{Batt,el}}$ ergibt sich aus der Summe der elektrischen Leistung des Elektromotors $P_{\mathrm{EM,el}}$ und des Gleichspannungswandlers $P_{\mathrm{DC-DC}}$. Die chemische Leistung $P_{\mathrm{Batt,chem}}$ wird basierend auf der Ruhespannung U_0, dem Innenwiderstand R_{i} und der elektrischen Leistung der Batterie berechnet (Gl. 4.13).

$$\begin{aligned} P_{\mathrm{Batt,el}} &= P_{\mathrm{EM,el}} + P_{\mathrm{DC-DC}} \\ P_{\mathrm{Batt,chem}} &= \frac{{U_0}^2}{2R_{\mathrm{i}}} - U_0\sqrt{\frac{{U_0}^2 - 4R_{\mathrm{i}}P_{\mathrm{Batt,el}}}{4{R_{\mathrm{i}}}^2}} \end{aligned} \tag{4.13}$$

Im Rahmen der Veröffentlichung von Koch et al. wurden fünf batterieelektrische Fahrzeuge in den Verkehrssimulator SUMO integriert und validiert [110]. Um eine realistische Verteilung der Fahrzeugklassen zu gewährleisten, wurden statistische Daten zur Pkw-Bestandsaufteilung nach Segmenten aus dem Kraftfahrt-Bundesamt entnommen und in Tabelle A.1.4 dargestellt. Im Jahr 2023 liegt der Anteil der Mini, Kleinwagen und Kompaktklasse am PKW-Bestand bei ca. 49 %. Der Anteil der Mittelklasse, obere Mittelklasse und Oberklasse beträgt 16 % während Geländewagen, Vans und andere Fahrzeugtypen insgesamt einen Anteil von 35 % aufweisen [111]. Zusätzlich wird für jede Fahrzeugklasse ein repräsentatives Fahrzeugmodell aus [110] ausgesucht und der validierte Energiebedarf in WLTC angegeben. Der Energiebedarf beinhaltet einen gemittelten Ladeeffizienzgrad von 90 %.

Damit ist eine ausreichende realistische Abbildung der Verkehrsteilnehmer im städtischen Bereich ermöglicht, wodurch die Auswirkungen der kooperativen Fahrfunktion auf den Energiebedarf analysiert werden können.

4.4 Verifizierung der Simulationsumgebung

Um eine umfassende und detaillierte Untersuchung der kooperativen Fahrfunktion in simulierten Verkehrsszenarien zu ermöglichen, werden in diesem Abschnitt die Verkehrsszenarien verifiziert und mittels zuvor erläuterten Verkehrskenngrößen charakterisiert. Dies trägt entscheidend zur Genauigkeit und Reproduzierbarkeit der bevorstehenden Erkenntnisse bei.
In einem ersten Schritt wird eine mikroskopische Evaluierung der Simulationsszenarien auf der Ebene der Fahrerverhaltensparameter durchgeführt. Diese Analyse bezieht sich insbesondere auf das Beschleunigungs- und Folgefahrtverhalten, wodurch das Verkehrsverhalten auf individueller Fahrzeugebene überprüft wird. Im Anschluss wird eine makroskopische Analyse durchgeführt, welche sich auf den durchschnittlichen Energiebedarf und die Geschwindigkeit der simulierten Verkehrsteilnehmer bezieht. Daraus ergibt sich ein globales Bild des Verkehrsflusses und der Effizienz des Systems. Fundamentaldiagramme werden verwendet, um die Verkehrsstärke und Verkehrsdichte für unterschiedliche Gesamtzahl von Fahrzeugen zu beschreiben.
Drei Szenarien mit einer variierenden maximalen Fahrzeuganzahl $n_{\mathrm{Fzg,max}} = 200, 250$ und 300 werden betrachtet. Für jede dieser Kategorien werden zehn Simulationen durchgeführt. Für die Vergleichbarkeit der Verkehrsszenarien mit unterschiedlicher maximalen Fahrzeuganzahl fahren die Fahrzeuge in jeder Simulation eines Szenarios verschiedene, zufällig generierte Routen ab. Die Routen aller Fahrzeuge in einer Simulation sind für jedes Szenario identisch. Unter Berücksichtigung einer angenommenen minimalen Durchschnittsgeschwindigkeit von 13 km/h und einer Gesamtfahrstreckenlänge von 12,88 km wird jede Simulation zur Verifizierung der Verkehrsszenarien für eine Dauer von 3.500 Sekunden durchgeführt.
In den folgenden Abbildungen 4.4 und 4.5 werden das Geschwindigkeits- und Beschleunigungsverhalten sowie das Folgeverhalten anhand der Verteilung der relativen Geschwindigkeit und des Abstands veranschaulicht. Die Parametereinstellung des Fahrzeugfolgemodells IDM ist für alle Simulationen identisch, somit kann beobachtet werden, dass die Häufigkeitsverteilungen der Beschleunigung, Geschwindigkeit und des Abstands bei unterschiedlicher Gesamtfahrzeuganzahl nur geringfügige Änderungen aufweisen..

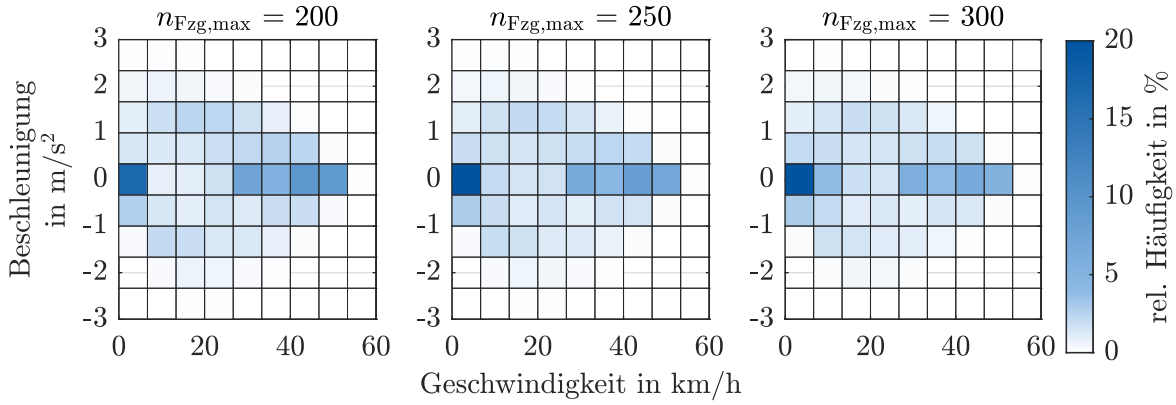

Abbildung 4.4: Darstellung der Beschleunigung gegenüber der Geschwindigkeit bei Verkehrssimulationen mit unterschiedlicher Anzahl an Fahrzeugen

Die in Abbildung 4.4 dargestellte Verteilung veranschaulicht, dass sich die Beschleunigung und Ge-

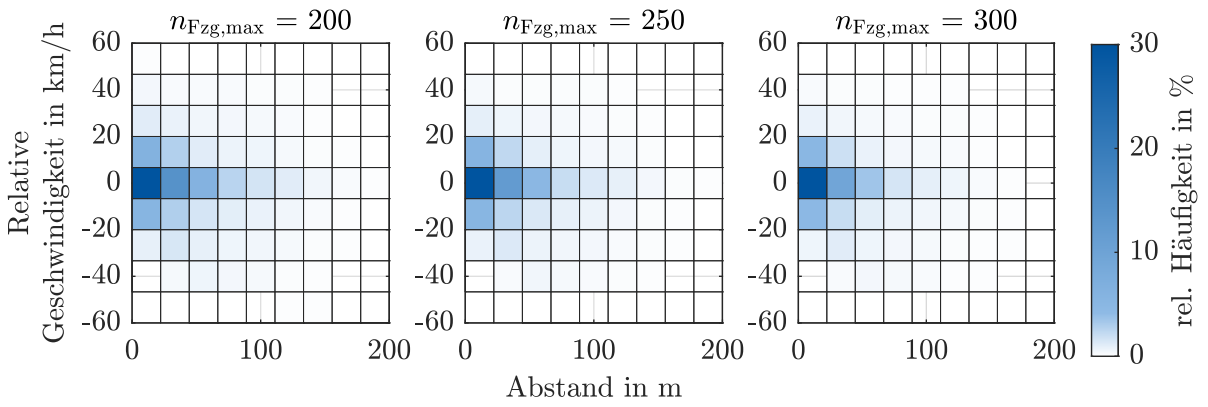

Abbildung 4.5: Darstellung des Folgeverhaltens mithilfe der relativen Geschwindigkeit und des Abstands bei Verkehrssimulationen mit unterschiedlicher Anzahl an Fahrzeugen

schwindigkeit hauptsächlich in zwei Bereichen befinden. Der erste davon ist der Stillstand, bei dem sowohl Geschwindigkeit als auch Beschleunigung den Wert Null erreichen. Der zweite Bereich ist gekennzeichnet durch eine Geschwindigkeit im Intervall von 40 bis 50 km/h und einer geringen Beschleunigung nahe 0 m/s^2. Die Maximalwerte der Beschleunigung und Verzögerung liegen bei etwa 2 m/s^2 beziehungsweise -2,5 m/s^2, während die Höchstgeschwindigkeit bei ca. 55 km/h erreicht wird. Abbildung 4.5 liefert einen Einblick in die Verteilung der relativen Geschwindigkeit und des Abstands, die das Folgeverhalten der Fahrzeuge beschreiben. Es ist zu beobachten, dass die Fahrzeuge dazu tendieren, dem vorausfahrenden Fahrzeug mit einem Abstand von 0 bis 60 Metern und einer geringen relativen Geschwindigkeit zwischen -20 und 20 km/h zu folgen. Dabei wird der maximale detektierbare Abstand durch den Verkehrssimulator SUMO auf 200 m begrenzt.

Positive relative Geschwindigkeiten implizieren eine höhere Geschwindigkeit des vorausfahrenden Fahrzeugs. Eine mögliche Verkehrssituation ist, wenn das vorausfahrende Fahrzeug eine LSA bereits passiert hat während das nachfolgende Fahrzeug an dieser LSA verkehrsbedingt verzögert wird. Hierbei nimmt die relative Geschwindigkeit zwischen den beiden Fahrzeugen zu und führt zur Erhörung des Abstands.

Negative relative Geschwindigkeiten legen nahe, dass das nachfolgende Fahrzeug seine Geschwindigkeit in Reaktion auf das vorausfahrende Fahrzeug mit einer gewissen zeitlichen Verzögerung anpasst, insbesondere wenn das vorausfahrende Fahrzeug die Geschwindigkeit verringert. Das bedeutet, die Geschwindigkeitsprofile beider Fahrzeuge tendieren dazu, synchron zu sein, wobei die Geschwindigkeitsänderungen des vorausfahrenden Fahrzeugs im Wesentlichen die Geschwindigkeitsanpassungen des nachfolgenden Fahrzeugs bestimmen.

Die Übereinstimmung der Häufigkeitsverteilung bei Simulationen mit unterschiedlichen Gesamtanzahl an Fahrzeugen legt nahe, dass die mikroskopische Simulation auf der Ebene der Fahrerverhaltensparameter eine hinreichende Genauigkeit aufweist, um kooperative Fahrfunktionen effektiv zu untersuchen.

Zusätzlich zur mikroskopischen Verifizierung auf der Ebene der FFE wird in der nachfolgenden Analyse eine Betrachtung der makroskopischen Verkehrskenngrößen durchgeführt. In Abbildung 4.6 wird der durchschnittliche Energiebedarf aller Fahrzeuge visualisiert. Die Simulationen werden für unterschiedliche maximale Fahrzeuganzahlen durchgeführt und die Ergebnisse entsprechend farblich

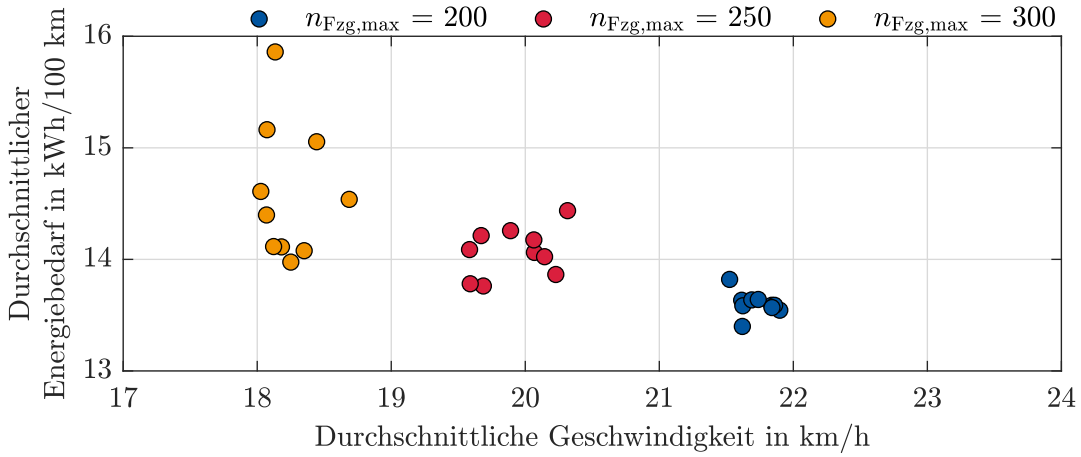

Abbildung 4.6: Darstellung des Energiebedarfs gegenüber der Durchschnittsgeschwindigkeit der Verkehrssimulation mit unterschiedlicher Anzahl an Fahrzeugen

codiert dargestellt. Konkret repräsentiert die blaue, rote und gelbe Farbe die Simulation mit einer maximalen Fahrzeuganzahl von jeweils 200, 250 und 300.

Unter Berücksichtigung einer maximalen Anzahl von 200 Fahrzeugen in der betrachteten Simulationsumgebung variieren der durchschnittliche Energiebedarf und die durchschnittliche Geschwindigkeit zwischen 13,40 und 13,82 kWh/100 km bzw. zwischen 21,52 und 21,90 km/h. Wenn die maximale Anzahl an Fahrzeugen auf 250 erhöht wird, wird eine leichte Zunahme des durchschnittlichen Energiebedarfs auf Werte zwischen 13,76 und 14,44 kWh/100 km beobachtet, während die durchschnittliche Geschwindigkeit auf den Bereich zwischen 19,58 und 20,32 km/h abnimmt. Es ist zu bemerken, dass diese Geschwindigkeit im Durchschnitt etwa 8 % niedriger ausfällt als bei einer Fahrzeuganzahl von 200, wobei der Energiebedarf um etwa 3,7 % höher ist. Wenn die Fahrzeuganzahl weiter erhöht wird, zeigt sich ein ähnliches Verhalten. Mit einer Anzahl von 300 Fahrzeugen verringert sich die durchschnittliche Geschwindigkeit auf einen Wertebereich von 18,03 bis 18,69 km/h, während der durchschnittliche Energiebedarf auf 13,98 bis 15,86 kWh/100 km steigt.

Die zugrundeliegende Ursache dieser Beobachtungen ist, dass eine Erhöhung der Fahrzeuganzahl, bei konstanter Routenlänge, zu einer höheren Verkehrsdichte führt. Dies resultiert in einer verminderten durchschnittlichen Geschwindigkeit und einem gesteigerten Energiebedarf aufgrund erhöhter Brems- und Beschleunigungsmanöver sowie einer allgemein niedrigeren durchschnittlichen Geschwindigkeit.

Die Verkehrsdynamik kann anhand dem in Abbildung 4.7 dargestellten Fundamentaldiagramm beschrieben werden. Hierbei werden die Verkehrsstärke und -dichte von allen zuvor ausgewählten Straßenabschnitten eingetragen.

Bei einer maximalen Anzahl von 200 Fahrzeugen in der Simulationsumgebung wird die Verkehrsdichte auf einen Bereich zwischen 6 und 53 Fahrzeugen pro Kilometer begrenzt, während die Verkehrsstärke zwischen 133 und 1143 Fahrzeugen pro Stunde variiert. Eine Erhöhung der maximalen Fahrzeuganzahl auf 250 resultiert in einem Anstieg dieser Kenngrößen, wobei die Verkehrsdichte in einem Bereich zwischen 6 und 73 Fahrzeugen pro Kilometer und die Verkehrsstärke zwischen 157 und 1237 Fahrzeugen pro Stunde liegt. Mit einer weiteren Erhöhung auf 300 Fahrzeuge in der Simulationsumgebung werden diese Werte auf 7 bis 73 Fahrzeuge pro Kilometer für die Verkehrsdichte und 194 bis 1430 Fahrzeuge pro Stunde für die Verkehrsstärke erweitert.

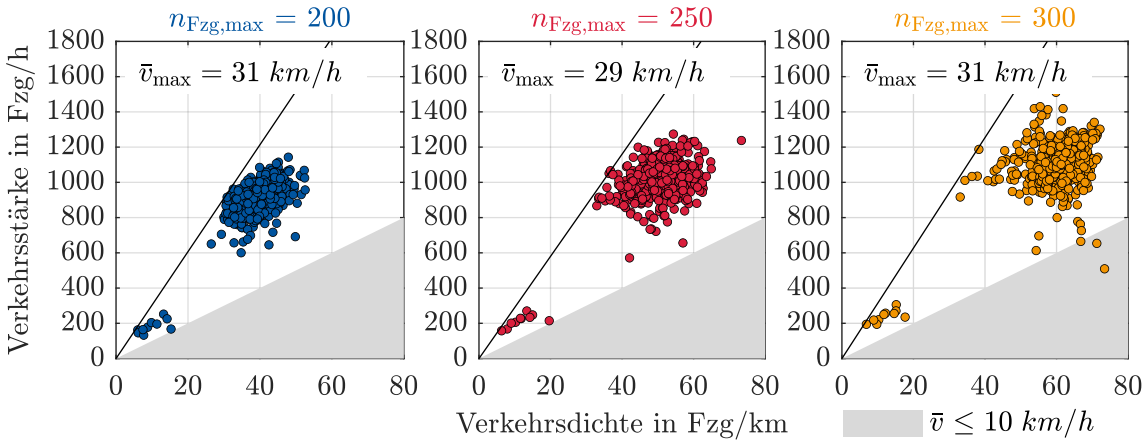

Abbildung 4.7: Darstellung der Verkehrssimulation mit unterschiedlicher Anzahl an Fahrzeugen im Fundamentaldiagramm

Mit einer Erhöhung der maximalen Fahrzeuganzahl in der Simulation weist die maximale durchschnittliche Geschwindigkeit $\bar{v}_{\text{max}}$, wie in der Abbildung 4.7 durch eine schwarze Linie repräsentiert, den Wert 31 km/h bzw. 29 km/h auf. Zusätzlich lässt sich beobachten, dass der Anteil der Straßenabschnitte mit niedriger durchschnittlicher Geschwindigkeit mit steigender Fahrzeugzahl zunimmt. Bei einer Gesamtzahl von 300 Fahrzeugen in der Simulation wird die niedrigste durchschnittliche Geschwindigkeit auf einem Straßenabschnitt auf unter 7 km/h reduziert. Darüber hinaus beträgt der Anteil der Straßenabschnitte, die mit einer durchschnittlichen Geschwindigkeit von weniger als 10 km/h befahren werden, ca. 0,5 %. Dies weist auf eine intensivierte Verkehrsdichte und somit auf eine potenzielle Verkehrsüberlastung hin, die durch die Zunahme der Fahrzeuganzahl und den nicht ausreichenden Verkehrsraum verursacht wird. Um eine präzise Validierung kooperativer Fahrfunktion in einem realistischen und nicht überlasteten Verkehrssimulationsumfeld zu gewährleisten, werden in dieser Arbeit eine maximale Fahrzeuganzahl von 200, 250 und 300 festgelegt.

Durch die Analyse des Fahrverhaltens, der Korrelation zwischen Energiebedarf und durchschnittlicher Geschwindigkeit sowie der Untersuchung der Verkehrskenngrößen anhand des Fundamentaldiagramms lässt sich feststellen, dass das simulierte Fahrverhalten der Erwartung entspricht. Des Weiteren befinden sich die ermittelten Werte der analysierten Kenngrößen ebenfalls in einem realistischen Bereich. Infolgedessen werden die vorgelegten Verkehrs- und Simulationsszenarien sowohl aus der verkehrsdynamischen Perspektive als auch unter Berücksichtigung des Fahrverhaltens und des Energiebedarfs als valide Abbildung der realen Verkehrsumgebung bewertet. Dies bietet eine robuste Grundlage für umfassende Tests und Evaluationen der kooperativen Fahrfunktion.

5 Trajektorienprädiktion umgebender Verkehrsteilnehmer

In zukünftigen Verkehrssystemen könnten Szenarien entstehen, in denen ein signifikanter Prozentsatz des Verkehrs aus kommunikationsfähigen und automatisierten Fahrzeugen besteht. Diese vernetzten Verkehrsteilnehmer können Daten untereinander austauschen und ihre individuellen Intentionen kommunizieren, wodurch eine verbesserte Koordination und Effizienz im Verkehrsfluss erreicht werden kann. Allerdings wird es eine Übergangsphase geben, in der automatisierte Fahrfunktionen innerhalb eines gemischten Verkehrsumfelds mit konventionell gesteuerten Verkehrsteilnehmern koexistieren. Eine entscheidende Herausforderung besteht darin, die Intentionen von nicht kommunikationsfähigen Verkehrsteilnehmern in der Umgebung abzuschätzen und zu interpretieren, um einen sicheren und effizienten Verkehrsfluss zu gewährleisten.
In der vorliegenden Dissertationsschrift werden zwei Methoden zur Vorhersage der Trajektorien umgebender Verkehrsteilnehmer implementiert. Die longitudinale Geschwindigkeit des direkten VFs wird mithilfe eines Prädiktionsmodells vorhergesagt, das auf den Arbeiten von Wegener et al. [1] basiert. Zur Vorhersage der longitudinalen und lateralen Geschwindigkeit von Fahrzeugen auf benachbarten Fahrstreifen während eines Fahrstreifenwechsels wird ein auf ML basierendes Prädiktionsmodell entwickelt. Dieses Modell zielt darauf ab, mögliche Blockierungen eines Fahrstreifenwechselvorgangs durch Fahrzeuge mit kooperativer Fahrfunktion vorherzusagen. Auf Grundlage dieser Vorhersage kann die kooperative Fahrfunktion entsprechend reagieren und proaktiv Maßnahmen ergreifen, um eine Blockierung des Fahrstreifenwechsels zu vermeiden.
Dieses Kapitel beginnt mit einer Erläuterung der theoretischen Grundlagen des MLs. Darauf aufbauend werden die verwendeten LSTM Netzwerke vorgestellt. Im weiteren Verlauf wird der Prozess der Datengenerierung und -verarbeitung für beide Methoden dargelegt. Abschließend wird die Trainingsumgebung, die zur Entwicklung der LSTM-Modelle verwendet wird, vorgestellt und die spezifischen Einstellungen und Parameter des Trainingsprozesses erläutert. Letztlich werden die Ergebnisse der Evaluierung der trainierten Prädiktionsmodelle präsentiert.

5.1 Grundlagen des maschinellen Lernens

Maschinelles Lernen umfasst verschiedene Methoden zur automatisierten Mustererkennung in Datenmengen und dient zur Vorhersage zukünftiger Daten sowie zur Unterstützung von Entscheidungsprozessen [112]. Der Lernprozess kann grundsätzlich in drei Grundkategorien eingeteilt werden: überwachtes Lernen, unüberwachtes Lernen und bestärkendes Lernen [113].
Beim unüberwachten Lernen identifiziert ein Modell selbständig Muster und Zusammenhänge in unverarbeiteten Daten, häufig mit dem Ziel der Datenklassifizierung. Das bestärkende Lernen hingegen erlernt Strategien, um die Ausgabe einer Belohnungsfunktion zu maximieren, indem eine Nutzenfunktion durch iterative Anpassung approximiert wird [113].

Beim überwachten Lernen liegt der Fokus auf dem Erlernen einer Zuordnung von Eingabe- auf Ausgabedaten, wofür eine Menge von zugehörigen Trainingsdaten erforderlich ist [113]. Eingabedaten können verschiedenartig sein und enthalten Merkmale, die eine Mustererkennung und folglich die Zuweisung einer Ausgabe ermöglichen. Künstliche neuronale Netze werden häufig für überwachtes Lernen angewandt, wobei der Lernprozess verschiedene Phasen durchläuft, einschließlich Datenerfassung, Auswahl der Netzwerktopologie, Strukturparametrisierung, Training und Evaluierung mit Testdaten. [114]
In dieser Arbeit werden in Anhang A.2.1 theoretische Grundlagen künstlicher neuronaler Netze erläutert. Hierbei sind die rekurrenten neuronalen Netze (RNN) aufgrund ihrer inhärenten rekursiven Struktur für die Verarbeitung sequenzieller Daten besonders geeignet. Daher stellen RNN die präferierte Netzwerkarchitektur für die Entwicklung des Prädiktionsmodells dar und werden im nachfolgenden Abschnitt detailliert beleuchtet.

5.1.1 Rekurrente neuronale Netzwerke

Die elementare Einheit eines RNNs ist durch direkte Rückkopplung charakterisiert, wobei der eigene Ausgang eines Neurons als zusätzlicher Eingang dient. Wie in Abbildung 5.1 auf der linken Seite dargestellt, bezeichnet bei einem RNN der versteckte Status h_t die Ausgänge einer RNN-Schicht, externe Eingänge werden als x_t gekennzeichnet. Eine typische versteckte Schicht eines RNNs besteht aus einer einzelnen Neuronenschicht mit einer Tangens hyperbolicus Funktion als Aktivierungsfunktion [115].

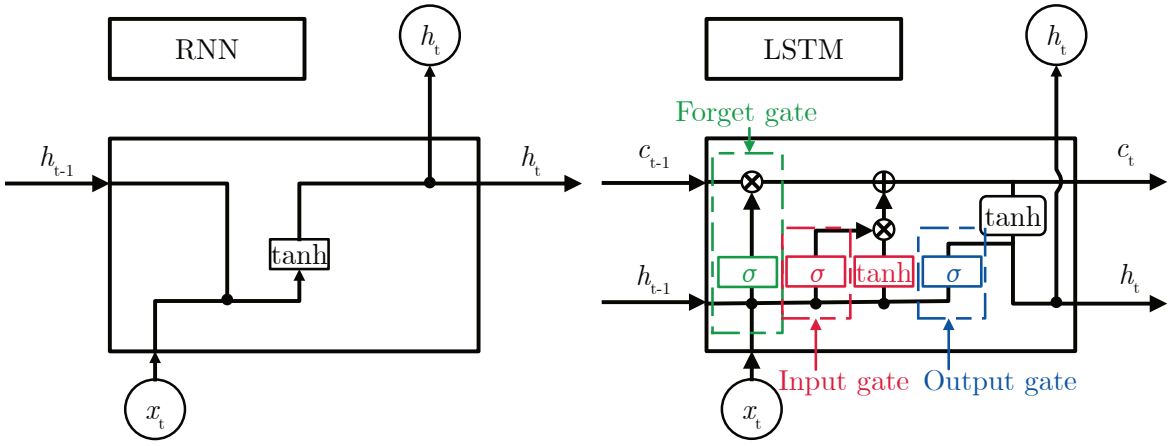

Abbildung 5.1: Schematische Darstellung des internen Aufbaus eines RNN-Moduls (links) und eines LSTM-Moduls (rechts) nach [116]

Ein besonderes Merkmal der RNN ist deren Fähigkeit, durch den kettenartigen Aufbau eine Art Gedächtnis zu implementieren. Dies ermöglicht die Verarbeitung von sequenziellen Daten, da Informationen aus vorherigen Eingängen in die Berechnung aktueller Ausgaben miteinbezogen werden können. [114]
Trotz der Stärken können bei der Anwendung von RNN auf lange Sequenzen Herausforderungen, wie das Phänomen des verschwindenden Gradienten auftreten. Dabei werden die partiellen Ableitungen während des Trainingsprozess so gering, dass der Lernvorgang beeinträchtigt wird. Zur Lösung dieser Problemstellung und zur Verbesserung der Anwendbarkeit von RNN auf längere Sequenzen werden

neuartige auf RNN basierende Architekturen wie die LSTM-Netzwerke entwickelt [114].

Long Short-Term Memory Netzwerke

LSTM Netzwerke stellen eine Modifikation der RNN Netzwerke dar, die dazu dienen, das Problem verschwindender Gradienten im Trainingsprozess zu vermeiden [117]. Diese auf RNN basierende Architekturen verfügen über vier interne Neuronenschichten, die zusammen drei Sorten von Toren (engl: Gates) bilden, welche zur Steuerung unterschiedlicher Funktionen dienen. Des Weiteren ergänzen LSTM das RNN um einen Zellzustand c_t, der dem verbesserten Erhalt von Informationen aus früheren Zeitschritten dient [115], [116]. Abbildung 5.1 zeigt den internen Aufbau einer LSTM-Zelle auf der rechten Seite.
Die inneren Strukturen einer LSTM-Zelle, darunter die Gates, steuern den Informationsfluss durch die Zelle. Diese Gates umfassen das Forget-Gate, das Input-Gate und das Output-Gate (in Abbildung 5.1 jeweils grün, rot und blau umrandet). Die Berechnung der Ausgaben des jeweiligen Gates ist in Anhang A.2.2 beschrieben. Aufgrund des Steuermechanismus ist ein LSTM-Netzwerk in der Lage zu erlernen, wann diese Informationen aus vergangenen Zuständen vergessen oder aktualisiert werden soll. Dadurch eignet sich das LSTM-Netzwerk besonders gut für Aufgabenstellungen mit Langzeitabhängigkeiten und findet breite Anwendung in verschiedenen Bereichen der sequenziellen Datenverarbeitung [115].

Anwendung zur Prädiktion sequenzieller Daten

Die Einsatzmöglichkeiten von LSTM-Netzwerken für die prädiktive Sequenzanalyse sind vielfältig. Abhängig von der Struktur der Eingabe- und Ausgabedaten können vier unterschiedliche Anwendungstypen von LSTM-Netzwerken unterschieden werden : Eins-zu-Viele, Viele-zu-Eins, Viele-zu-Viele und Sequenz-zu-Sequenz. [118] Diese Kategorisierung ermöglicht eine gezielte Auswahl und Implementierung von LSTM-Netzwerken in Abhängigkeit von den spezifischen Anforderungen der zu analysierenden sequenziellen Daten.
Eine Viele-zu-Viele Prädiktion, wobei eine Eingabesequenz in eine Ausgabesequenz überführt wird, entspricht der Zielsetzung dieser Dissertationsschrift, bei der Vorhersagen für einen festgelegten Zeithorizont erfolgen. Ein Single-Shot-Modell[1] kann hierfür angewendet werden, bei dem die Eingabesequenz als Vektor mit einer Länge, die der Anzahl der zu betrachtenden Zeitschritte T entspricht, an das neuronale Netzwerk weitergegeben wird. Das rekurrente Modell analysiert die Eingabesequenz nach relevanten Informationen, akkumuliert einen internen Zustand und generiert nach der Verarbeitung des letzten Zeitschritts eine vektorielle Ausgabe mit den vorhergesagten Werten. Die Länge des Ausgabevektors entspricht dem gewünschten Prädiktionshorizont T.
Das Erstellen eines auf das spezifische Problem abgestimmten Netzwerks stellt allerdings nur den erste Schritt dar. Um praktikable Vorhersagen zu erzielen, muss das Modell in einem iterativen Prozess mit repräsentativen Trainingsdaten trainiert werden.

[1] Single-Shot-Modell: Ein Ansatz innerhalb von LSTM-Netzwerken, bei dem die Vorhersagen für mehrere zukünftige Zeitschritte simultan in einer einzigen Evaluierung der Eingabedaten erfolgen, im Gegensatz zu einem sequenziellen Prozess, der mehrere iterative Durchgänge erfordern würde. [119]

5.1.2 Trainingsprozess

Die Konzeption eines künstlichen neuronalen Netzes erfordert die Festlegung einer geeigneten Architektur und von Parametern, wie beispielsweise der Anzahl an Neuronen oder LSTM-Einheiten pro Schicht. Nach dem Aufbau des Netzwerks werden die Gewichtungen der Neuronen zufällig initialisiert, anschließend erfolgt die Anpassung der Gewichtungen während eines iterativen Trainingsprozesses mittels der zuvor akquirierten, repräsentativen Daten. Abbildung 5.2 visualisiert diesen Prozess in vereinfachter Form für eine Prädiktion mit vektorieller Ein- und Ausgabe für einen Iterationsschritt.

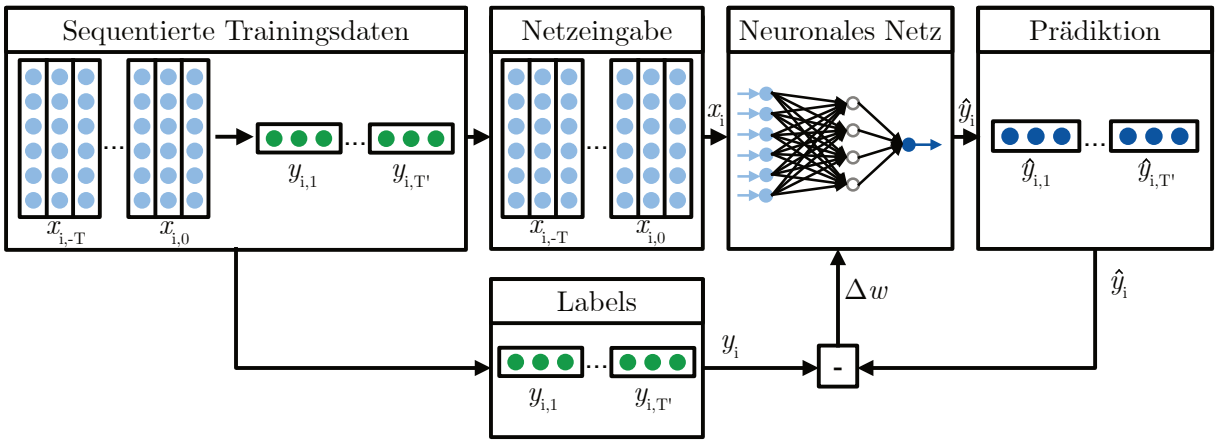

Abbildung 5.2: Trainingsprozess eines neuronalen Netzes im Zusammenhang einer Prädiktion mit vektorieller Ein- und Ausgabe für einen Iterationsschritt

Das Netzwerk erhält die Eingaben x_i und berechnet die Prädiktion $\hat{y}_i$. Diese werden mit den korrespondierenden Labels y_i verglichen, auf Basis der daraus resultierenden Differenz werden die Gewichtungen angepasst. Dieser Prozess wiederholt sich über eine voreingestellte Anzahl an Epochen. Alternativ können Abbruchkriterien definiert werden, wie z. B. die vorzeitige Beendigung des Trainings, sobald eine bestimmte Metrik sich über eine festgelegte Anzahl an Epochen nicht verbessert. Das Training eines neuronalen Netzwerks zielt darauf ab, die Gewichtungen der einzelnen Neuronen so anzupassen, dass akkurate Ausgabedaten generiert werden können, selbst für bisher unbekannte Eingaben. Die detaillierte Beschreibung des Algorithmus zum Trainieren des neuronalen Netzwerks wird in Anhang A.2.3 dargestellt.

Trainingsdaten werden normalerweise in Batches aufgeteilt, wobei deren Prädiktion vom Netzwerk erzeugt wird, bevor die Gewichtungen angepasst werden. Die Daten werden zwischen den iterativ ausgeführten Epochen umsortiert, um das Erlernen von Mustern, die auf der Reihenfolge der Eingabedaten basieren, zu verhindern. Sollten mehrere Epochen in Folge keine Verbesserungen erbringen, kann das Training vorzeitig beendet werden.

Eine Überanpassung des Netzwerks an die Trainingsdaten, kann zu hoher Präzision während des Trainings, jedoch zu geringer Genauigkeit bei neuen Daten führen. Sogenannte Dropout-Schichten, bei denen eine zufällige Anzahl von Neuronen pro Iteration deaktiviert werden, können dieses Problem abschwächen. In der finalen Anwendung werden alle Neuronen wieder aktiviert.

5.2 Datengenerierung und -verarbeitung

Repräsentative Trainingsdaten stellen das Fundament für die Entwicklung eines ML-basierten Prädiktionsmodells dar. Um eine realistische Abbildung von Verkehrsflüssen zu gewährleisten und die notwendige Varianz zu erzeugen, werden die in Kapitel 4 verifizierten Methoden zur Generierung der Verkehrssimulationen eingesetzt. Wie zuvor erläutert, kommen für die vorliegende Dissertationsschrift zwei spezifische Prädiktionsmodelle zum Einsatz: eines fokussiert sich auf die Prädiktion der longitudinalen Geschwindigkeitstrajektorie vorausfahrender Fahrzeuge, während das andere die longitudinale und laterale Geschwindigkeitstrajektorie umliegender nicht-automatisierter Fahrzeuge während deren Fahrstreifenwechsel prädiziert. Für diesen Zweck werden während der Verkehrssimulation spezifische Daten erfasst und für die weiterführende Verarbeitung vorbereitet.

5.2.1 Vorgehen zur Datengenerierung

Die Verkehrssimulation dient zur Datengenerierung, wobei es notwendig ist, eine spezifische Methodik zur Extraktion der Trainingsdaten zu entwickeln. Diese Vorgehensweise ist vergleichbar mit der eines realen Forschungsfahrzeugs, das Daten mithilfe von umfangreicher Sensorik aus dem Verkehrsgeschehen erfasst. Die simulierten Egofahrzeuge werden mit entsprechenden Algorithmen ausgestattet, um umliegende Fahrzeuge zuverlässig zu detektieren sowie Fahrzeug- und Verkehrsdaten in der virtuellen Umgebung zu erheben. Freie Fahrten durch den simulierten Verkehrsfluss entlang der definierten Referenzrouten erlauben die Erhebung von Rohdaten der identifizierten Verkehrsteilnehmer, die im Anschluss zu verwendbaren Trainingsdaten verarbeitet werden. Dies resultiert in der Erstellung von Datensätzen bestehend aus Eingabesequenzen und dazugehörigen Labels, die für das Training der neuronalen Netze benötigt werden. Die entwickelte Methodik zur Umgebungsdetektion wird im Folgenden beschrieben, gefolgt von der Erläuterung der Vorgehensweisen zur finalen Generierung der Trainingsdaten für beide Prädiktionsmodelle.

Umgebungsdetektion

In SUMO wird die Identifizierung der bis zu sechs umgebenden Fahrzeuge durch die Anwendung der Schnittstellenfunktionen TraCI realisiert. Durch eine Kombination der Rückgabewerte der Funktion zur Detektion der benachbarten Verkehrsteilnehmer und der Methodik zur Darstellung des Zusammenhangs wird im Rahmen dieser Dissertationsschrift ein robustes System zur Umgebungserfassung in einem Radius von 100 Metern um das Egofahrzeug entwickelt.
Neben Informationen über die simulationsinternen Fahrzeugnummern der detektierten Fahrzeuge und deren Positionen relativ zum Egofahrzeug, liefert die Fahrzeugdetektion die longitudinalen Abstände zwischen der Vorderseite des Egofahrzeuges und der Rückseite des betreffenden umgebenden Verkehrsteilnehmers. Zusätzlich wird für vorausfahrende Fahrzeuge auf benachbarten Fahrstreifen ermittelt, ob deren aktuellen Umgebungszustand den Aktivierungsbedingungen des Prädiktionsmodells für Fahrstreifenwechsel entspricht. In diesem Fall muss das benachbarte Fahrzeug auf der linken oder rechten Seite zwischen dem Egofahrzeug und dessen Vorderfahrzeug liegen.

Nach der Implementierung der Detektion relevanter umliegender Fahrzeuge in die jeweiligen Egofahrzeuge, werden diese verwendet, um Daten von den erfassten Fahrzeugen zu sammeln. Auf dieser Basis werden zunächst Trainingsdatensätze für das Prädiktionsmodell des vorausfahrenden Fahrzeugs und in einem nachfolgenden Schritt für das Modell zur Prädiktion der umliegenden Fahrzeuge während des Fahrstreifenwechsels generiert.

Datenerhebung für Prädiktionsmodell eines Vorausfahrzeugs

Nach den Erkenntnissen von Wegener et al. erfordert das Prädiktionsmodell, das sich auf das vorausfahrende Fahrzeug konzentriert, sowohl Daten des vorausfahrenden Fahrzeugs als auch Informationen der anstehenden LSA.[1] Die folgende Abbildung 5.3 veranschaulicht die zur Prädiktion der longitudinalen Geschwindigkeit des vorausfahrenden Fahrzeugs erforderlichen Parameter. Diese werden in Tabelle 5.1 aufgelistet und die entsprechenden Wertintervalle eingetragen. Darüber hinaus sind die benötigten Zeithorizonte der Daten zu einem Zeitschritt k aufgeführt.

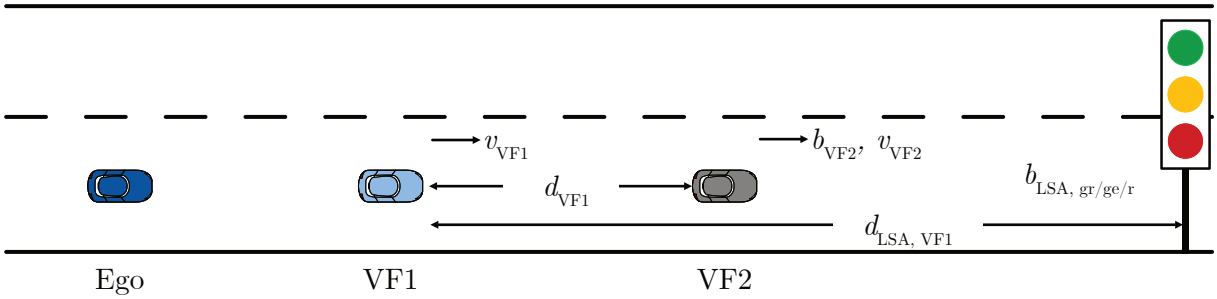

Abbildung 5.3: Darstellung der Eingangsdaten für das Prädiktionsmodells des Vorausfahrzeugs

Tabelle 5.1: Eingangsdaten des Prädiktionsmodells des Vorausfahrzeugs

Parameter	Zeichen	Werteintervall		Zeithorizont
Longitudinale Geschwindigkeit des VF1	v_{VF1}	$0 \leq v_{VF1} \leq 17\ m/s$		k
Abstand zwischen VF1 und VF2	d_{VF1}	$0 \leq d_{VF1} \leq 100\ m$		k
Abstand zur nächsten LSA	$d_{LSA,VF1}$	$0 \leq d_{LSA,VF1} \leq 200\ m$		k
LSA-Schaltung	$b_{LSA,gr}$ $b_{LSA,ge}$ $b_{LSA,r}$	Grünphase: Gelbphase: Rotphase:	$b_{LSA,gr} = 1$ $b_{LSA,ge} = 1$ $b_{LSA,r} = 1$	$k, ..., k+n$
Existenz des VF2	b_{VF2}	Nicht vorhanden: Vorhanden:	$b_{VF2} = 0$ $b_{VF2} = 1$	k
Longitudinale Geschwindigkeit des VF2	v_{VF2}	$0 \leq v_{VF2} \leq 17\ m/s$		k

Die durchgeführte Verkehrssimulation verwendet eine Abtastzeit von 0,1 Sekunden, während die Zeitschrittweite für das Prädiktionsmodell eine Sekunde beträgt. Bei einen gegebenen Zeitschritt k werden die aktuellen Werte der longitudinalen Geschwindigkeit des vorausfahrenden Fahrzeugs v_{VF1} als Eingangsdaten benötigt. Für die Informationen bezüglich des Abstands zur nächsten Lichtsignalanlage $d_{LSA,VF1}$, der Existenz eines weiteren Fahrzeugs vor dem vorausfahrenden Fahrzeug b_{VF2} und dessen Geschwindigkeit v_{VF2} sowie der Abstand zwischen dem vorausfahrenden Fahrzeug und dessen vorausfahrenden Fahrzeugs d_{VF1} werden ebenfalls die aktuellen Werte benötigt.

Die LSA-Schaltung hat einen maßgeblichen Einfluss auf die Geschwindigkeitsänderung des vorausfahrenden Fahrzeugs. Daher erfolgt eine separate Erfassung der Informationen zu den Grün-, Gelb- und Rotphasen. Für jeden der folgenden $n = 30$ Zeitschritte werden die Zustände der Grün-, Gelb- und Rotphasen, $b_{\mathrm{LSA,gr}}$, $b_{\mathrm{LSA,ge}}$ und $b_{\mathrm{LSA,r}}$, separat aufgenommen und als insgesamt 90 Eingangsgrößen in das Prädiktionsmodell eingespeist. Die Sequenzlänge aller Parameter beträgt hierbei 30s, damit das LSTM-Netzwerk die zeitliche Abhängigkeit in den Eingabedaten erkennen kann.

Datenerhebung für Prädiktion während eines Fahrstreifenwechsels

Im Vergleich zum Prädiktionsmodell eines Vorausfahrzeugs wird die Prädiktion der Bewegungstrajektorien während eines Fahrstreifenwechsels von umgebenden und nicht-automatisierten Fahrzeugen (NAF) nur in bestimmten Situationen benötigt. Aus diesem Grund erfordert dies eine spezifische Anpassung des Trainingsdatensatzes auf diese besonderen Fälle. Hierbei soll die Fahrstreifenwechseltrajektorie vorhergesagt werden, wenn ein Fahrzeug in einer bestimmten Position vor dem Egofahrzeug lokalisiert ist und deren Fahrtrichtungsanzeiger aktiviert hat, jedoch den Fahrstreifenwechsel nicht sofort ausführen kann, wenn der angestrebte Fahrstreifen aktuell blockiert ist. Solche Szenarien treten in den simulierten Trainingsszenarien nicht häufig genug auf, um ausreichende Trainingsdaten zu generieren. Daher wird die Methodik zur Detektion des Fahrstreifenwechsels erweitert, bei dem innerhalb des simulierten Verkehrsflusses außerhalb der Umgebung des Egofahrzeugs nach passenden Fahrstreifenwechelszenarien gesucht wird.

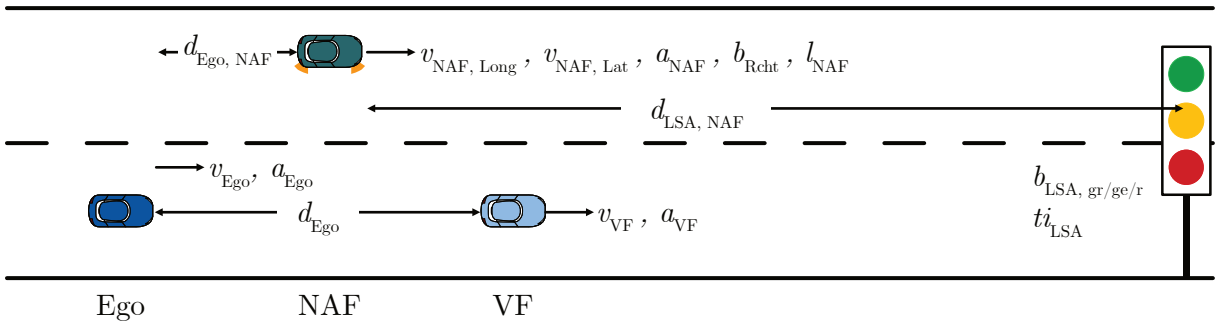

Abbildung 5.4: Darstellung der Eingangsdaten für das Prädiktionsmodells während eines Fahrstreifenwechels

Abbildung 5.4 stellt die Parameter dar, die zur Prädiktion der longitudinalen Geschwindigkeit eines umliegenden NAFs herangezogen werden. Die Identifizierung von Fahrzeugen, deren Fahrstreifenwechsel von einem anderen Fahrzeug blockiert werden, sowie der beteiligten Fahrzeuge, die den Fahrstreifenwechselmanöver blockieren, erfolgt anhand der Rückmeldungen des Fahrstreifenwechselstatus aus SUMO. Während des gesamten Fahrstreifenwechselprozesses werden die Fahrzeuge, die einen Fahrstreifenwechsel blockieren, als Egofahrzeuge klassifiziert. Diese sammeln die relevanten Daten von den als einscherenden NAF markierten Fahrzeugen und den zugehörigen Informationen des VFs sowie der vorausliegenden LSA, wie in Tabelle 5.2 dargelegt.
Bei einem betrachteten Zeitschritt k werden verschiedene Größen erfasst, die für einen Fahrstreifenwechselvorgang relevant sind. Diese beinhalten zunächst die longitudinale Geschwindigkeit und Beschleunigung des Egofahrzeugs v_{Ego} und a_{Ego}, wobei gleichzeitig der Abstand zu anderen Verkehrsteilnehmern, hier insbesondere zum VF d_{Ego} und zum NAF $d_{\mathrm{Ego,NAF}}$, aufgezeichnet wird. Da-

Tabelle 5.2: Eingangsdaten des Prädiktionsmodells für umliegende nicht-automatisierte Fahrzeuge

Parameter	Zeichen	Werteintervall	Zeithorizont
Longitudinale Geschwindigkeit des Egofahrzeugs	v_{Ego}	$0 \leq v_{\text{Ego}} \leq 17\ m/s$	k
Longitudinale Beschleunigung des Egofahrzeugs	a_{Ego}	$-4,5m/^2 \leq a_{\text{Ego}} \leq 6m/^2$	k
Abstand zwischen Egofahrzeug und VF	d_{Ego}	$0 \leq d_{\text{Ego}} \leq 100\ m$	k
Abstand zwischen Egofahrzeug und NAF	$d_{\text{Ego,NAF}}$	$-10 \leq d_{\text{Ego,NAF}} \leq 100\ m$	k
Longitudinale Geschwindigkeit des VFs	v_{VF}	$0 \leq v_{\text{VF}} \leq 17\ m/s$	k
Longitudinale Beschleunigung des VFs	a_{VF}	$-4,5m/^2 \leq a_{\text{VF}} \leq 6m/^2$	k
Longitudinale Geschwindigkeit des NAFs	$v_{\text{NAF,Long}}$	$0 \leq v_{\text{NAF,Long}} \leq 17\ m/s$	k
Laterale Geschwindigkeit des NAFs	$v_{\text{NAF,Lat}}$	$-1,3\ \leq v_{\text{NAF,Long}} \leq 1,3\ m/s^2$	k
Longitudinale Beschleunigung des NAFs	a_{NAF}	$-4,5m/^2 \leq a_{\text{NAF}} \leq 6m/^2$	k
Abstand vom NAF zur nächsten LSA	$d_{\text{LSA,NAF}}$	$0 \leq d_{\text{LSA,NAF}} \leq 200\ m$	k
LSA-Schaltung	$b_{\text{LSA,gr}}$ $b_{\text{LSA,ge}}$ $b_{\text{LSA,r}}$	Grünphase: $b_{\text{LSA,gr}} = 1$ Gelbphase: $b_{\text{LSA,ge}} = 1$ Rotphase: $b_{\text{LSA,r}} = 1$	k
Dauern der aktuellen LSA-Schaltung	ti_{LSA}	$0 \leq ti_{\text{LSA}} \leq 45s$	k
Fahrzeuglänge des NAFs	l_{NAF}	$0 \leq l_{\text{NAF}} \leq 10m$	k
Fahrtrichtungsanzeiger des NAFs	b_{Rcht}	$0 \leq b_{\text{Rcht}} \leq 1$	k

durch, dass die räumlichen und geschwindigkeitsbasierten Beziehungen zwischen den Fahrzeugen einen signifikanten Einfluss auf das Fahrstreifenwechselverhalten haben können, wird ergänzend die longitudinale Geschwindigkeit und Beschleunigung des VFs, v_{VF} und a_{VF} erfasst.

Darüber hinaus zielt die Datenerfassung auf eine möglichst umfassende Darstellung des Fahrverhaltens des NAFs ab. In diesem Kontext spielen die longitudinale und die laterale Geschwindigkeit des NAFs, $v_{\text{NAF,Long}}$ und $v_{\text{NAF,Lat}}$, sowie die Beschleunigung des NAFs a_{NAF} eine wichtige Rolle. Zusätzlich sind der Abstand des NAFs zur nächsten LSA $d_{\text{LSA,NAF}}$ und der Schaltzustand der LSA $b_{\text{LSA,gr}}$, $b_{\text{LSA,ge}}$ und $b_{\text{LSA,r}}$ sowie die Dauer der aktuellen LSA-Schaltung für den aktuellen Zeitschritt separat aufgezeichnet. Schließlich fließen auch die Fahrzeuglänge des NAFs l_{NAF} und der Zustand dessen Fahrtrichtungsanzeigers b_{Rcht} in die Datenakquisition ein, um mögliche zusätzliche Einflussfaktoren auf die Fahrstreifenwechselentscheidung zu berücksichtigen. In diesem Fall beträgt die Sequenzlänge aller Parameter 5 s, und die Abtastzeit liegt bei 0,1 s.

Zusätzlich zur Datenerfassung in Szenarien, in denen ein Fahrstreifenwechsel stattfindet, wird bewusst die Aufzeichnung von Fahrzeugdaten berücksichtigt, in denen ein umliegender Verkehrsteilnehmer die Absicht zum Fahrstreifenwechsel signalisiert, jedoch kein Fahrstreifenwechsel vor dem betrachteten Egofahrzeug ausgeführt wird. Die Datenaufnahme endet entweder, wenn das Fahrzeug nicht mehr im relevanten Bereich zwischen dem Egofahrzeug und dem VF ist oder falls das Fahrzeug den Fahrtrichtungsanzeiger deaktiviert hat. Im letzteren Fall wird die Datenaufnahme fortgesetzt,

bis in der zeitlich weitest zurückliegenden Eingabesequenz kein Signal mehr für einen beabsichtigten Fahrstreifenwechsel zu erkennen ist.
Dieser methodische Ansatz führt zur Generierung eines spezifisch auf den Anwendungsfall zugeschnittenen Trainingsdatensatzes für das Prädiktionsmodell des Fahrstreifenwechsels. Durch die Integration sowohl von erfolgreichen und nicht erfolgreichen Fahrstreifenwechsel-Szenarien in den Datensatz kann eine robuste und zuverlässige Modellbildung gewährleistet werden.

5.2.2 Erzeugung der Trainingsdatensätze

Entsprechend der zuvor dargelegten methodischen Herangehensweise werden zwei verschiedene Datensätze generiert, die jeweils für das Training eines spezifischen neuronalen Netzwerks genutzt werden. Für das vorausfahrende Fahrzeugprädiktionsmodell absolvieren zwölf Egofahrzeuge jeweils vier Runden entlang der Referenzroute innerhalb einer zufällig generierten Verkehrssimulation, wodurch die Trainingsdaten erstellt werden.
Hinsichtlich der Fahrstreifenwechselprädiktion absolviert ein Egofahrzeug 15 Runden die selben Route, während im Rahmen eines ergänzenden Szenarios in Intervallen von 50 Sekunden insgesamt 20 weitere Egofahrzeuge gestartet werden.
Für das Modell, das das vorausfahrende Fahrzeug betrifft, werden 224.339 Sequenzen generiert und in den Trainingsprozess des longitudinalen Prädiktionsmodelle integriert. Für den Trainingsdatensatz des Fahrstreifenwechselmodells werden 82 Fahrstreifenwechsel manuell selektiert und entsprechend der zuvor beschriebenen Methode verarbeitet. Darüber hinaus werden 34 weitere Szenarien manuell ausgewählt, in denen ein Fahrzeug zwar einen Fahrstreifenwechsel signalisiert, jedoch nicht vor dem Egofahrzeug einschert, beispielsweise aufgrund eines unzureichenden Abstandes zum vorausfahrenden Fahrzeug. Insgesamt umfasst der finale Datensatz für das Fahrstreifenwechselmodell 6.428 entsprechend gelabelte Trainingsdatensätze.
Im finalen Schritt der Datenverarbeitung werden sämtliche Sequenzwerte der beiden Datensätze auf den Bereich zwischen 0 und 1 normiert, um eine gleichmäßige Skalierung der Parameter für den Trainingsprozess zu gewährleisten. Dazu werden die Werte der Parameter durch die in den Tabellen 5.1 und 5.2 angegebenen Maximalwerte geteilt. Parameter, deren Werteintervalle nicht von 0 bis zu einem entsprechenden Maximalwert reichen, werden zusätzlich gemäß Gleichung Gl. 5.1 normiert, wobei die jeweilige Messung als Variable dient.

$$x_{\mathrm{norm,i}} = \frac{x_{\mathrm{i}} - x_{\mathrm{min}}}{x_{\mathrm{max}} - x_{\mathrm{min}}} \tag{5.1}$$

Die generierten Datensätze werden schließlich in Trainings- und Validierungsdaten aufgeteilt. Jeweils 80 % eines Datensatzes werden als Trainingsdaten verwendet. Die verbleibenden 20 % werden während des Trainings zur Validierung herangezogen und dienen als Entscheidungsgrundlage für die Bestimmung des final im Trainingsprozess eingesetzten neuronalen Netzwerks. Die Entscheidung, auf eine separate Aufteilung der Daten in ein Testdatenset zu verzichten, wird dadurch begründet, dass zur Evaluierung der trainierten neuronalen Netze eine zusätzliche Verkehrssimulationsinstanz erstellt wird, in der die trainierten Netze für eine kontinuierliche Vorhersage eingesetzt werden.

5.3 Entwicklung des Prädiktionsmodells

Unter Verwendung der zuvor erzeugten Trainingsdaten können anschließend die benötigten neuronalen Netzwerke trainiert werden. Im nachfolgenden Kapitel wird zunächst auf die konzipierten und trainierten Netztopologien eingegangen. Danach erfolgt eine Beschreibung der konfigurierten Parameter, die den Trainingsprozesses bestimmen.

5.3.1 Formulierung der Netztopologien

Wie zuvor dargelegt, existiert kein analytischer Ansatz zur Bestimmung einer optimalen Netzwerkstruktur. Daher ist der Entwicklungsprozess geeigneter neuronaler Netze als iterativer Prozess zu verstehen, bei dem verschiedene Netzwerktopologien trainiert und getestet werden müssen. Die zwei benötigten neuronalen Netze zur Prädiktion des Vorausfahrzeugs und des Fahrstreifenwechsels bestehen in ihren Grundstrukturen aus Verknüpfungen von LSTM- und Dropout-Schichten.
Gemäß den Ausführungen von [1] wird das Prädiktionsmodell für das vorausfahrende Fahrzeug als sequenzielles neuronales Netzwerk konzipiert, welche jeweils über eine Ein- und Ausgabeschicht verfügt. Eine grafische Darstellung der Netzwerkarchitektur, bestehend aus zwei verdeckten LSTM- und Dropout-Schichten, ist in Abbildung 5.5 dargestellt.

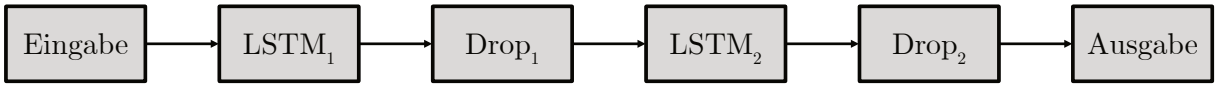

Abbildung 5.5: LSTM Netztopologie eines Prädiktionsmodells für das Vorausfahrzeug

Details zur Anzahl der verdeckten Schichten und der eingesetzten LSTM-Einheiten sind in Tabelle 5.3 aufgelistet. Zusätzlich werden die konstanten Werte für die Dropout-Schichten angegeben, welche den Anteil der während des Trainings zufällig zu deaktivierenden Verbindungen festlegen.

Tabelle 5.3: Trainierte Netztopologie für das Prädiktionsmodell des Vorausfahrzeugs

Verdeckte Schicht	$LSTM_1$	$LSTM_2$
Anzahl an Neuronen	128	64
Dropout	0,2	0,2

Angepasst an die Funktionsweise des Fahrstreifenwechselmodells, das durch Analyse der Gesamtsituation eine Prädiktion sowohl der longitudinalen als auch der lateralen Geschwindigkeit eines einscherenden NAFs generiert, wird eine Netzwerktopologie gewählt, die auf Basis einer gemeinsamen Eingabe zwei Ausgaben hervorbringt. Abbildung 5.6 zeigt die strukturelle Konfiguration eines exemplarischen neuronalen Netzwerks für das Fahrstreifenwechselmodell in der entworfenen verzweigten Struktur mit drei versteckten Schichten. Die beiden Verzweigungen werden in der vorliegenden Dissertationsschrift identisch parametrisiert. Die im Folgenden angegebenen Zahlen bezüglich der versteckten Schichten des Fahrstreifenwechselmodells beziehen sich demnach sowohl auf die Verzweigung zur Ermittlung der longitudinalen als auch auf den zur Bestimmung der lateralen Geschwindigkeit.
Sechs unterschiedliche Netztopologien werden zur Prädiktion des Fahrstreifenverhaltens herangezogen. Diese unterscheiden sich hauptsächlich in der Anzahl der implementierten verdeckten Schichten

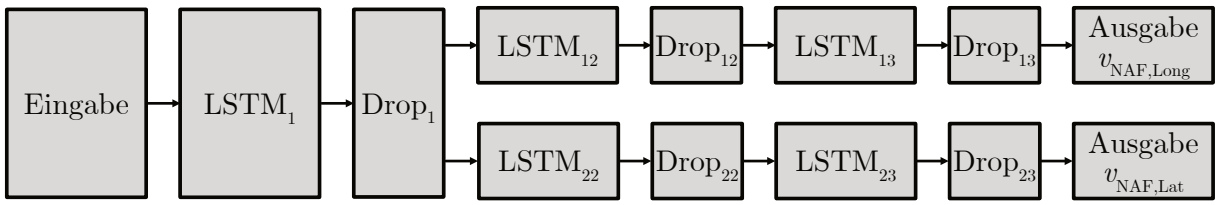

Abbildung 5.6: LSTM Netztopologie eines Prädiktionsmodells für das Fahrstreifenwechsel

und der Anzahl an LSTM-Einheiten. In Tabelle 5.4 sind die verwendeten Parametrisierungen dargestellt. Darüber hinaus enthält die Tabelle die konstanten Werte für die Dropout-Schichten.

Tabelle 5.4: Trainierte Netztopologie für das Prädiktionsmodell des Fahrstreifenwechsels

Verdeckte Schicht		$LSTM_1$	$LSTM_2$	$LSTM_3$
Anzahl an Neuronen	Topologie 1	256	128	64
	Topologie 2	128	64	64
	Topologie 3	100	50	50
	Topologie 4	256	128	-
	Topologie 5	128	64	-
	Topologie 6	100	50	-
	Dropout	0,25	0,2	0,1

Das neuronale Netz für das Fahrstreifenwechselprädiktionsmodell wird entsprechend der vorgestellten Topologien initialisiert. Vor dem Start der jeweiligen Trainingsprozesse ist es jedoch erforderlich, die weiteren Hyperparameter zu definieren. Diese stellen die kennzeichnenden Werte dar, welche den Verlauf und die Dynamik des Trainingsprozesses wesentlich beeinflussen und steuern.

5.3.2 Auswahl der Hyperparameter

Sämtliche Trainingsprozesse werden über eine maximale Anzahl von 2000 Epochen durchgeführt. Für die Optimierung kommt der Adam-Optimierer zum Einsatz, dessen Parametrisierung entsprechend den Empfehlungen in [120] hinsichtlich der initialen Lernrate η_0, des Gradientenabfallfaktors β_1 und des quadratischen Gradientenabfallfaktors β_2, sowie der Teiler-Summand ϵ angepasst wird. Durchgängig wird der quadratische Mittelwert der Differenz zwischen den tatsächlichen Messwerten und den prädizierten Werten als Fehlerfunktion herangezogen (vgl. Gl. A.2.5). Dabei variiert die Batchgröße zwischen 2048 und 1024 Trainingsdatensätzen. Darüber hinaus wird eine Strategie zur Lernratenreduktion bei Stagnation des Lernprozesses eingeführt, wobei die Lernrate η mit einem Lernratenreduktionsfaktor f_η multipliziert wird, falls der Validierungsfehler innerhalb eines Optimierungszeitraums von I Epochen nicht verringert werden kann. Als endgültiges neuronales Netz wird das Modell aus der Trainingsphase ausgewählt, welches den niedrigsten Fehlerwert im Validierungsdatensatz aufweist. Tabelle 5.5 fasst die entsprechende Parametrisierung der Trainingsprozesse zusammen.

Nachdem die neuronalen Netzwerke initialisiert, die Hyperparameter definiert und der spezifische Trainingsdatensatz erstellt sind, kann der abschließende Prozess zur Entwicklung der benötigten Prädiktionsmodelle initiiert werden. Eine umfangreiche Analyse der erzielten Ergebnisse wird im nächsten Abschnitt präsentiert. Vorab wird jedoch der finale Entwicklungsprozess dargestellt, bei

Tabelle 5.5: Hyperparameter der Trainingsprozesse

Hyperparameter	Zeichen	Wert
Epochen		2000
Batchgröße		2048/1024
Lernratenreduktionsfaktor	f_η	0,5
Optimierungsintervall	I	15
Initiale Lernrate	η_0	0,001
Gradientenabfallfaktor	β_1	0,9
Quadratischer Gradientenabfallfaktor	β_2	0,999
Teiler-Summand	ϵ	10^{-8}

dem das Grundkonzept zusammen mit den trainierten Prädiktionsmodellen in die Simulationsumgebung integriert wird.

5.3.3 Integration und Bewertung der trainierten Prädiktionsmodelle

Für die Evaluierung der Prädiktionsmodelle werden die trainierten neuronalen Netzwerke in die Simulationsumgebung integriert und die erzielten Prädiktionen zu jedem simulierten Zeitschritt aufgezeichnet. Dies ermöglicht die kontinuierliche Prädiktion der Geschwindigkeitstrajektorien der umliegenden Verkehrsteilnehmer $v_{\text{Präd}}(k)$, die unter anderem als Grundlage für die nachfolgende Evaluierung der erreichten Ergebnisse dient. In einem anschließenden Bewertungsschritt werden diese mit den tatsächlichen Geschwindigkeitstrajektorien $v_{\text{Echt}}(k)$ der jeweiligen Fahrzeuge verglichen. Zusätzlich wird die Differenz der aus den Geschwindigkeiten berechneten zurückgelegten Strecke Δs ermittelt und die Prädiktionsgüte analysiert (vgl. Gl. 5.2).

$$\begin{aligned} \Delta v(k) &= v_{\text{Echt}}(k) - v_{\text{Präd}}(k) \\ \Delta s(k) &= s_{\text{Echt}}(k) - s_{\text{Präd}}(k) \end{aligned} \tag{5.2}$$

Auf der Grundlage des in Kapitel 5.2.1 beschriebenen Datengenerierungsprozesses erfasst das Egofahrzeug die erforderlichen Größen der umgebenden Verkehrsteilnehmer. Aufgrund der Eigenschaften von Folgefahrt und Fahrstreifenwechsel zeigt sich Erstere durch ein überwiegend stabiles und vorausschauendes Verhalten mit begrenzter spontaner Variation, während Letztere durch eine hohe Spontanität gekennzeichnet ist, die durch diverse Einflussfaktoren bedingt ist und typischerweise innerhalb weniger Sekunden erfolgt. Daher können Daten, die ein längeres Zeitintervall konstanter Folgefahrt umfassen, die Genauigkeit der Vorhersage spontaner Fahrstreifenwechselnmanöver potenziell beeinträchtigen. Vor diesem Hintergrund werden lediglich Daten der vergangenen dreißig und fünf Sekunden für die Prädiktionsmodelle herangezogen werden. Die erhobenen Werte werden nicht in einer stetig wachsenden Liste erfasst sondern in sogenannten Double-ended queues (Deques) mit einer maximalen Länge von 30 und 50 Einheiten gespeichert. Die jeweils aktuell erhobenen Werte werden somit aufgenommen und die Informationen des über dreißig oder fünf Sekunden zurückliegenden Zeitschrittes automatisch verworfen. Dies stellt nicht nur die Daten für die Vorausfahrzeugsprädiktion bereit, sondern erfasst auch die Informationen für den Fahrstreifenwechsel. Dadurch wird

die ständige Einsatzbereitschaft des Prädiktionsmodells für den Fahrstreifenwechsel sichergestellt, falls ein Verkehrsteilnehmer vor das Egofahrzeug einscheren möchte.
Die sich in jedem Zeitschritt neu ergebenden Eingabesequenzen in Form der Deques können nun als Eingangsdaten in die jeweiligen neuronalen Netze eingegeben werden, sodass in jedem Zeitschritt eine Vorhersage über das Fahrverhalten der umgebenden Verkehrsteilnehmer getroffen werden kann. Bei einer neuen Detektion werden die Daten mit konstanten Werten ergänzt, die das jeweilige Fahrzeug zum Zeitpunkt der erstmaligen Detektion aufweist.
Durch die Implementierung der Prädiktionsmodelle in der Simulationsumgebung konnte die Qualität der erzielten Prädiktionen in einem neuen Szenario überprüft werden, dessen Werte nicht in den Trainingsprozess einflossen. Die Ergebnisse der durchgeführten Evaluation werden im Folgenden präsentiert.

Evaluierung des Prädiktionsmodells eines Vorausfahrzeugs

In Abbildung 5.7 erfolgt eine detaillierte Darstellung, in der die prädizierten Trajektorien mit der realen Geschwindigkeit und zurückgelegten Strecke verglichen werden.

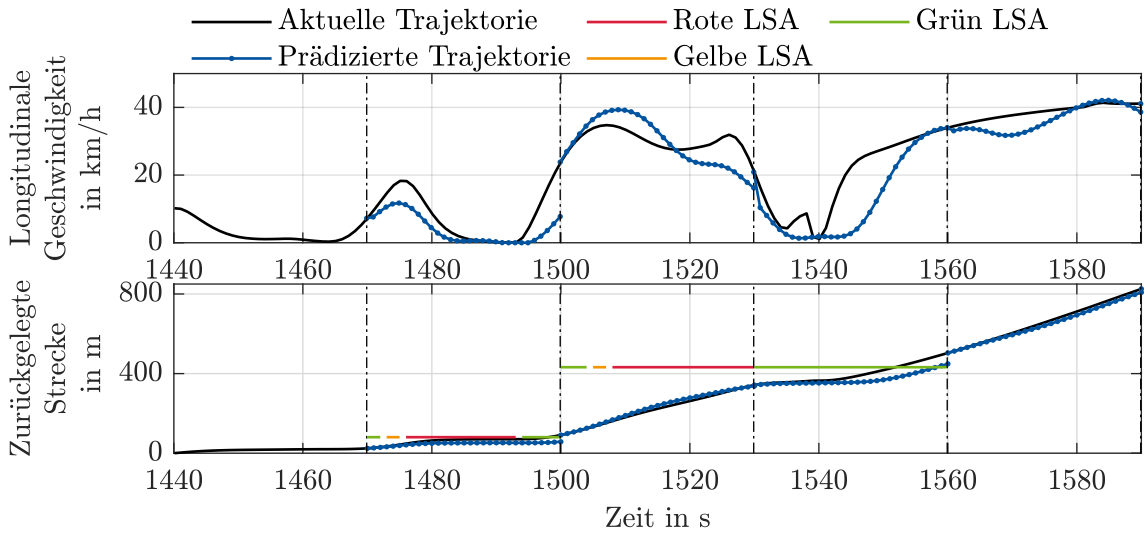

Abbildung 5.7: Vergleich der tatsächlichen und prädizierten Trajektorie zur Evaluierung des Prädiktionsmodells eines Vorausfahrzeugs

Innerhalb des betrachteten Zeitfensters zwischen 1470 s und 1485 s sowie zwischen 1510 s und 1540 s wird eine eindeutige Verzögerung der Geschwindigkeitstrajektorie prädiziert. Die initiale Verzögerungsphase ist von der Rotphase der vorausliegenden LSA abhängig. Die darauffolgende Beschleunigungsphase wird vom Modell mit reduzierter Intensität vorhergesagt, wobei jedoch das grundlegende Verhalten korrekt erfasst wird.
Nach der zweiten identifizierten Verzögerungsphase wird eine Geschwindigkeitstrajektorie nach dem Beginn der Grünphase bis zum nahezu vollständigen Stillstand präzise prädiziert, welche sich durch das Fahrverhalten des VFs begründen lässt. Es ist ersichtlich, dass die Verzögerung geringfügig vor der realen Zeitspanne und die Beschleunigungsphase in geringerer Intensität prädiziert wird. Die Analyse dieses Zeitabschnitts verdeutlicht, dass das Prädiktionsmodell die Längsdynamik des Fahrzeugs in Bezug auf LSA und in der Interaktion mit einem VF generell zuverlässig vorhersagt,

obwohl einige Abweichungen hinsichtlich der Intensität der beobachteten Fahrverhalten existieren. Zur Evaluierung der Prädiktionsgüte des Modells für das Vorausfahrzeug wird die Verteilung der Prädiktionsfehler der Geschwindigkeit Δv und der zurückgelegten Strecke Δs für jeden Zeitschritt über den Prädiktionshorizont $N_\mathrm{p} = 15$ s in Abbildung 5.8 dargestellt. Die Abbildung veranschaulicht statistische Kenngrößen wie den Median x_med, das untere Quartil x_{25} und das obere Quartil x_{75} in Form von Boxplots.

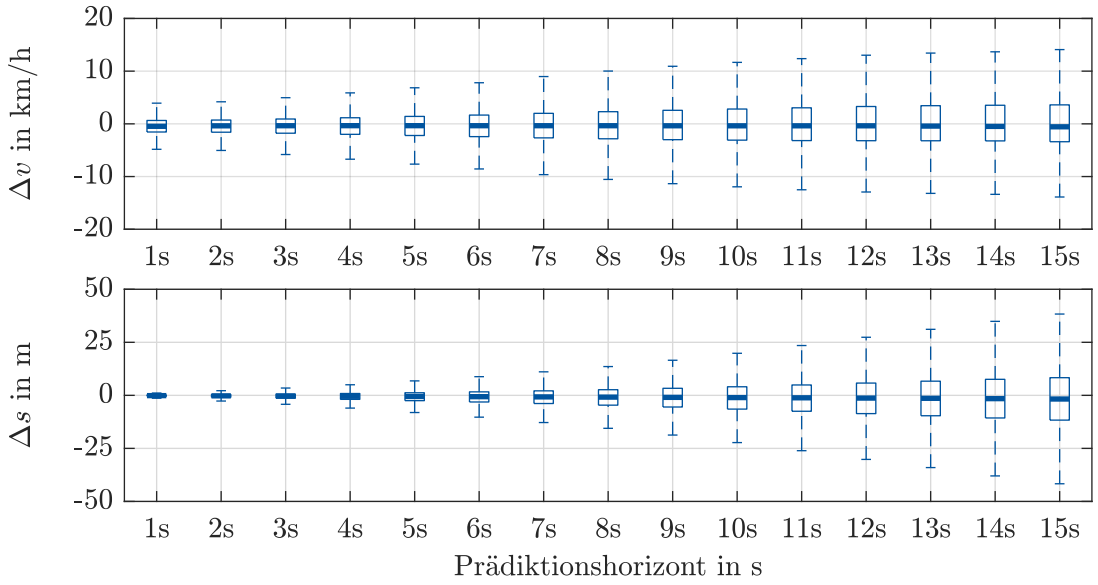

Abbildung 5.8: Verteilung der Prädiktionsfehler von longitudinaler Geschwindigkeit und zurückgelegter Strecke

Die Mediane der Abweichungen für Geschwindigkeit und zurückgelegte Strecke sind durch die breiten horizontalen Striche in den Boxplots gekennzeichnet. Diese sind nahezu konstant bei 0 km/h und 0 m über den gesamten Prädiktionshorizont, das darauf hindeutet, dass das Modell im Median keine signifikante Abweichung von der tatsächlichen Geschwindigkeit und zurückgelegten Strecke aufweist. Das untere Quartil der Prädiktionsfehler der Geschwindigkeit weist innerhalb des Prädiktionshorizont von einer bis zwölf Sekunden einen marginal geringeren Wert im Vergleich zum Betrag des oberen Quartils auf. Dies deutet darauf hin, dass das entwickelte Modell eine leichte Tendenz zur Unterschätzung der Geschwindigkeit des VFs zeigt.

Die mittleren 50 % der Geschwindigkeitsprädiktionen für den Prädiktionshorizont von einer Sekunde liegen zwischen -1,5 und 0,6 km/h. Diese Bandbreite erweitert sich bei einem Prädiktionshorizont von 15 Sekunden auf einen Wertebereich zwischen -3,4 und 3,6 km/h. Analog dazu liegen die mittleren 50 % der Daten für die Vorhersage der zurückgelegten Strecke bei einem Prädiktionshorizont von einer Sekunde zwischen -0,4 und 0,2 m. Bei einem Prädiktionshorizont von 15 Sekunden erweitert sich dieser Bereich auf -11,7 und 8,3 m.

Diese statistische Analyse liefert wertvolle Erkenntnisse über die Qualität des Prädiktionsmodells über verschiedene Prädiktionshorizonte hinweg und zeigt, dass das Modell in der Lage ist, präzise und zuverlässige Vorhersagen über kurze Prädiktionshorizonte zu liefern und weist auf eine zunehmende Ungenauigkeit bei einem längeren Prädiktionshorizont hin.

Die konkreten Auswirkungen der Ungenauigkeit des Prädiktionsmodells auf kooperative Fahrfunk-

tionen werden in einem nachfolgenden Kapitel (siehe Abschnitt 6.2.5) analysiert.

Evaluierung des Prädiktionsmodells während eines Fahrstreifenwechsels

Zur Ermittlung des optimalen Prädiktionsmodells für Fahrstreifenwechselmanöver ist es primär erforderlich, Situationen zu definieren, in denen Fahrstreifenwechsel durch ein weiteres Fahrzeug verhindert werden. Die Evaluierung des Prädiktionsmodells stützt sich daher auf die longitudinalen und lateralen Trajektorien von 3.073 unterschiedlichen blockierten Fahrstreifenwechsel-Szenarien, was insgesamt 24.360 Sequenzen entspricht.
In einer initialen Analyse der Resultate werden die absoluten longitudinalen und lateralen Positionsfehler (siehe Gl. 5.2) in den 15 Prädiktionshorizonten untersucht. Die ermittelten Daten sind in Tabelle 5.6 zusammengefasst.

Tabelle 5.6: Median der absoluten longitudinalen und lateralen Positionsfehler in Meter

Batch Größe	Topo.	Absolute longitudinale und laterale Positionsfehler in m									
		N_p =1 s		N_p=2 s		N_p=5 s		N_p=10 s		N_p=15 s	
		long.	lat.	long.	lat.	long.	lat.	long.	lat.	long.	lat.
2048	1	-0,09	0,20	-0,49	0,22	-4,83	0,39	-15,44	1,19	-21,67	2,11
	2	-0,31	0,12	-0.86	0,06	-4,24	-0,18	-12,75	**0,64**	-18,12	1,30
	3	-0,24	0,08	-0,69	0,08	-3,28	0,07	-12,99	0,97	-24,60	**0,98**
	4	-0,36	0,23	-1,11	0,39	-5,98	0,43	-14,48	1,34	-26,99	1,90
	5	-0,20	0,33	-0,69	0,53	-3,98	0,65	-12,41	1,24	-19,00	1,74
	6	**-0,02**	0,24	**-0,25**	0,40	**-2,42**	0,79	**-7,44**	1,69	**-12,11**	1,58
1024	1	-0,26	0,22	-0,83	0,37	-5,16	0,38	-17,65	1,53	-28,04	1,06
	2	-0,19	0,78	-0,62	1,19	-3,90	1,55	-13,10	1,61	-18,51	1,39
	3	-0,27	0,18	-0,78	0,29	-3,56	0,41	-9,94	1,16	-16,67	1,76
	4	-0,35	0,16	-1,10	0,30	-7,13	0,54	-20,00	1,05	-28,55	1,91
	5	-0,16	0,07	-0,57	0,09	-4,18	0,29	-15,00	0,89	-23,10	1,12
	6	-0,26	**0,02**	-0,72	**-0,04**	-4,11	**0,00**	-14,46	0,73	-21,19	1,21

Aufgrund der erhöhten Komplexität der betrachteten Fahrstreifenwechsel-Szenarien, in denen sich die Fahrzeuge gegenseitig beeinflussen, entstehen erwartungsgemäß größere Abweichungen in der Prädiktion des longitudinalen Fahrverhaltens. In Bezug auf die laterale Prädiktionsgenauigkeit ist zu berücksichtigen, dass die Prädiktion über den lateralen Geschwindigkeitsverlauf mit dem Fahrstreifenwechselprädiktionsmodell bereits erstellt werden kann, wenn ein solcher Fahrstreifenwechsel lediglich angekündigt, aber noch nicht eingeleitet wird. Eine zentrale Eigenschaft dieses Modells ist daher die indirekte Vorhersage des Fahrstreifenwechselbeginns.
Für die endgültige Auswahl des geeignetsten Netzwerks werden die Netzwerke mit der Topologie 6, Batch-Größe 2048 für die longitudinale Prädiktion, und Topologie 6, Batch-Größe 1024 für die laterale Prädiktion, identifiziert. Diese Netzwerke sind durch deren geringen absoluten Positionsfehler in den jeweiligen Richtungen am besten geeignet. Die relevanten Werte sind in Tabelle 5.6 hervorgehoben.
Abbildung 5.9 veranschaulicht exemplarisch einen Fahrstreifenwechsel, bei dem die prädizierten und realen Verläufe der longitudinalen und lateralen Geschwindigkeit sowie die dabei zurückgelegte Stre-

cke gegenübergestellt werden.

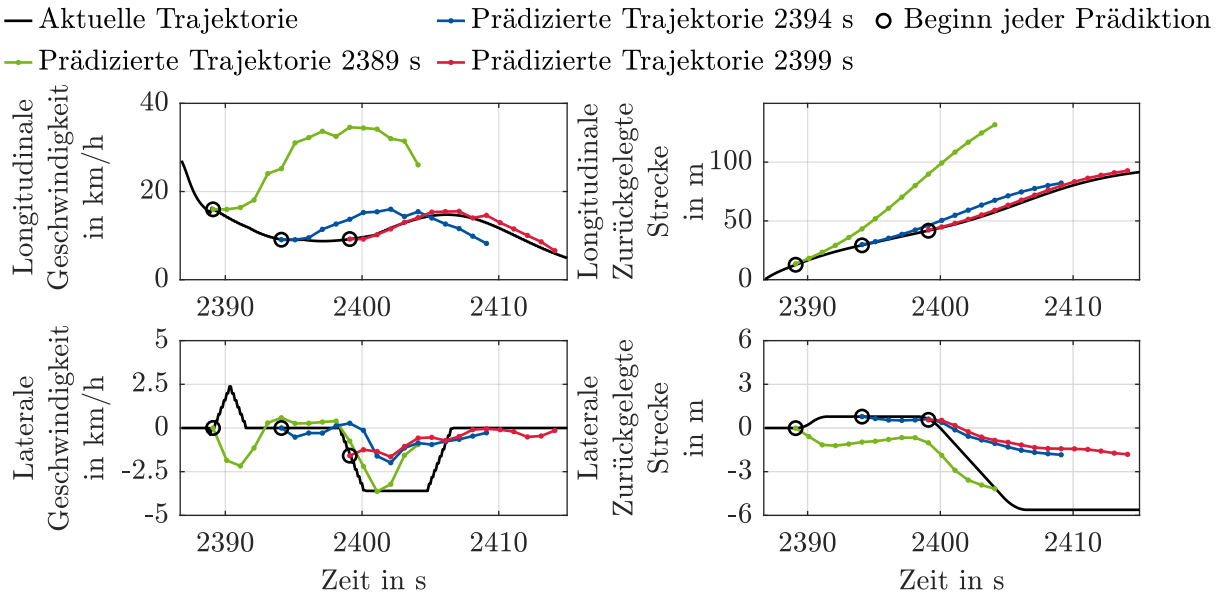

Abbildung 5.9: Gegenüberstellung der prädizierten und tatsächlichen longitudinalen und lateralen Geschwindigkeit sowie zurückgelegten Strecke mit LSTM-Netzwerk Topologie 6 Batch Größe 2048 (long.)/1024 (lat.) vor einem Fahrstreifenwechsel

In der dargestellten Abbildung visualisieren die Linien in Grün, Blau und Rot die prädizierte Verläufe der longitudinalen und lateralen Geschwindigkeiten sowie die zurückgelegten Strecken zu den Zeitpunkten 2389, 2394 und 2399 Sekunden. Die tatsächliche Geschwindigkeitstrajektorie wird durch die schwarz markierte Linie angezeigt.

Bei der Analyse des longitudinalen Geschwindigkeitsverlaufs lässt sich erkennen, dass das Prädiktionsmodell in der Lage ist, die charakteristische Dynamik des Geschwindigkeitsverlaufs, eine initiale Beschleunigung gefolgt von einer Verzögerung, vorherzusagen. Dennoch offenbart die Analyse zu dem Zeitpunkt 2389 s, zu dem die Intention zum Fahrstreifenwechsel detektiert wird, eine schnelle Zunahme der Fahrgeschwindigkeit. Diese Tendenz zur Überschätzung der Geschwindigkeit korrigiert sich einige Sekunden nach der Integration der Eingangsdaten des LSTM-Netzwerks mit den realen Fahrzeugdaten, woraufhin das Prädiktionsmodell beim Zeitpunkt 2394 s einen dem tatsächlichen Geschwindigkeitsprofil ähnlichen Verlauf vorhersagt. Es besteht eine zeitliche Differenz von etwa -5 Sekunden zwischen der prädizierten und der tatsächlichen Geschwindigkeit. Hinsichtlich der Prädiktion der lateralen Geschwindigkeit weist das Modell ebenfalls eine hinreichende Genauigkeit auf, die es ermöglicht, einen Fahrstreifenwechsel vorauszusagen. Dennoch ist auch hier eine zeitliche Verzögerung von etwa 2 Sekunden zu erkennen.

Diese Erkenntnisse weisen auf die Herausforderungen bei der zeitlichen Abstimmung zwischen den prädizierten und den tatsächlichen Geschwindigkeitsverläufen hin. Eine mögliche Erklärung für diese zeitliche Differenz könnte in der Komplexität und Vielfalt der Einflussgrößen eines Fahrstreifenwechsels liegen. Dennoch zeigt das Prädiktionsmodell, dass es in der Lage ist, die Vorhersagen auf Basis der weiteren Eingabedaten kontinuierlich an die Verkehrssituation anzupassen. Die prädizierte Trajektorie zum Zeitpunkt 2399 s in der Abbildung 5.9 verdeutlicht, dass das Modell zur Prädiktion der longitudinalen Geschwindigkeit die zeitliche Differenz mittels der weiteren Eingabedaten kom-

pensieren kann und dass die finale Geschwindigkeitsprädiktion nahezu dem tatsächlichen Verlauf entspricht.

Abbildung 5.10 und 5.11 präsentieren die jeweiligen statistischen Kenngröße der Prädiktionsfehler von longitudinaler und lateraler Geschwindigkeit für die gewählte Netztopologie 6 sowie die Batch-Größen von 2048 und 1024 in Form von Boxplots.

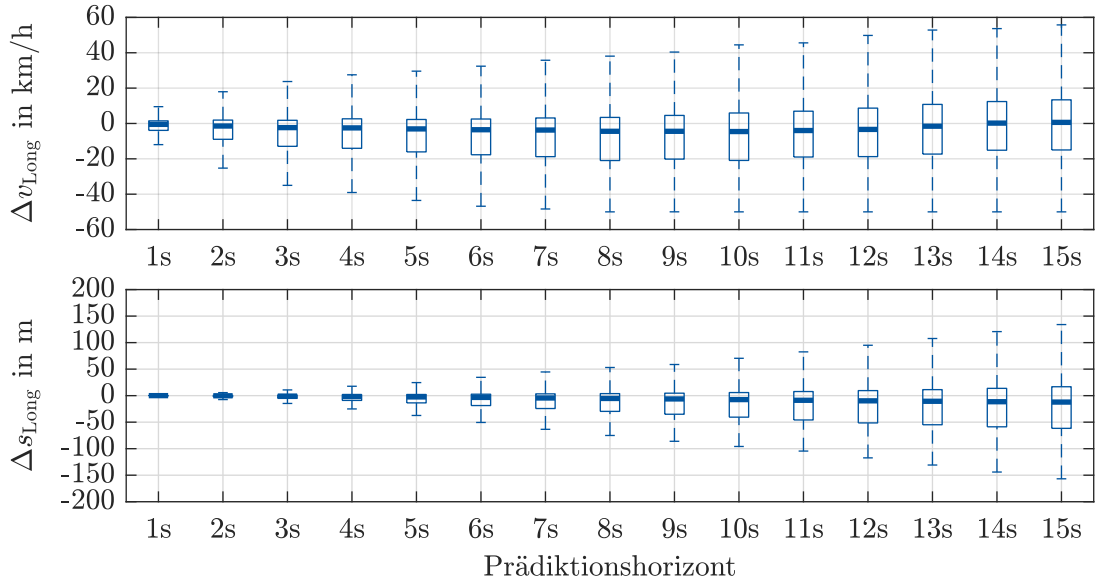

Abbildung 5.10: Prädiktionsfehler von longitudinaler Geschwindigkeit und zurückgelegter Strecke

Durch die Untersuchung der Prädiktionsfehler von longitudinaler Geschwindigkeit und zurückgelegter Strecke in Abbildung 5.10 wird ersichtlich, dass sich die Mediane der Geschwindigkeitsabweichung von -0,50 km/h bei einem Prädiktionshorizont von einer Sekunde auf -4,56 km/h bei neun Sekunden erhöhen. Bei einem Prädiktionshorizont von 15 Sekunden reduziert sich dieser Wert auf 0,62 km/h. Infolgedessen vergrößern sich die daraus berechneten Positionsfehler von -0,02 m zu -12,11 m.

Im Bereich der Geschwindigkeitsprädiktionen liegen die mittleren 50 % der Daten für einen Prädiktionshorizont von einer Sekunde zwischen -3,91 und 1,48 km/h. Mit steigendem Prädiktionshorizont auf 15 Sekunden erweitert sich diese Bandbreite auf einen Bereich zwischen -14,98 und 13,37 km/h. Analog dazu liegen die mittleren 50 % der Daten für die Prädiktion der zurückgelegten Strecke bei einem Prädiktionshorizont von einer Sekunde zwischen -0,65 und 0,34 m. Bei einem Prädiktionshorizont von 15 Sekunden erweitert sich dieser Bereich auf Werte zwischen -61,66 und 16,79 m.

Vergleichbar mit der bereits durchgeführten Untersuchung des longitudinalen Verhaltens während des Fahrstreifenwechsels zeigt Abbildung 5.11 die Prädiktionsfehler von lateraler Geschwindigkeit und zurückgelegter Strecke. In dieser Analyse ist festzustellen, dass die Mediane der lateralen Geschwindigkeitsabweichung nahezu bei 0 km/h verbleiben. Die sich daraus ergebende zurückgelegte Strecke steigt von 0,02 m bei einem Prädiktionshorizont von einer Sekunde auf 1,21 m bei einem Prädiktionshorizont von 15 Sekunden an.

Die mittleren 50% der Daten für Geschwindigkeitsprädiktionen liegen bei einem Prädiktionshorizont von einer Sekunde zwischen -0,47 und 0,26 km/h. Dieser Wertebereich erweitert sich auf -0,28 bis 2,47 km/h bei einem Prädiktionshorizont von fünf Sekunden und verringert sich danach wieder auf

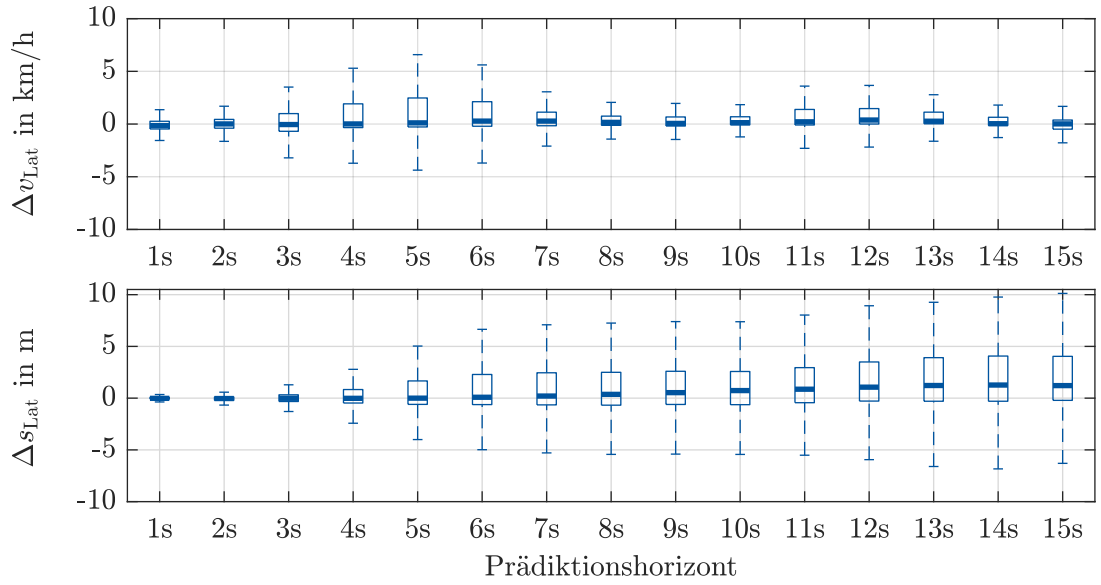

Abbildung 5.11: Prädiktionsfehler von lateraler Geschwindigkeit und zurückgelegter Strecke

einen Bereich von -0,48 bis 0,38 km/h. Demzufolge steigt der Bereich der mittleren 50% der Daten für die Prädiktion der zurückgelegten Strecke von -0,10 bis 0,08 m bei einem Prädiktionshorizont von einer Sekunde auf -0,21 bis 4,04 m an.

Die Beobachtung, dass die Ungenauigkeit der Prädiktion von einer bis zu fünf Sekunden zunimmt, lässt sich auf die Vielzahl an Faktoren zurückführen, die den Beginn eines Fahrstreifenwechsels beeinflussen. Beispielsweise spielen der Abstand zwischen dem Egofahrzeug und dem VF, sowie die Geschwindigkeiten aller beteiligten Fahrzeuge eine maßgebliche Rolle. Insbesondere die höheren Werte des oberen Quartils bei den Prädiktionshorizonten von drei bis sechs Sekunden deuten darauf hin, dass das Prädiktionsmodell dazu tendiert, einen späteren Beginn des Fahrstreifenwechsels vorherzusagen.

Die in diesem Kapitel entwickelten Methoden zur Prädiktion der longitudinalen Geschwindigkeitstrajektorie des direkten VFs und des potenziell einscherenden NAFs werden jeweils als Positionsbegrenzung der Kolonne und für die Koordination der Fahrmanöver in die kooperativen Fahrfunktionen eingesetzt. Die laterale Geschwindigkeitsprädiktion wird nicht in die kooperativen Fahrfunktionen einbezogen und dient an dieser Stelle nur zu Veranschaulichung der Qualität des Prädiktionsmodells. Die Struktur der Implementierung dieser Prädiktionsmodelle in die kooperative Fahrfunktion wird in dem nachfolgenden Kapitel ausführlich erläutert.

6 Prädiktive kooperative Fahrfunktion

Im folgenden Kapitel erfolgt eine ausführliche Darstellung des entwickelten Konzepts der prädiktiven kooperativen Fahrfunktion. Zunächst wird eine Einführung in die Grundprinzipien der modellprädiktiven Regelung gegeben, die als Kerntechnologie für die Implementierung der zentralisierten und kooperativen Fahrfunktion dient. Nachfolgend wird die Funktion der Folgefahrt thematisiert, die das Fundament des Gesamtkonzepts darstellt. Der Energiebedarf sowie die Verkehrsdichte werden hierbei in einem ausgewählten Folgefahrtszenario evaluiert. Abschließend wird das Management von Fahrmanövern beleuchtet. Dies umfasst das Aufschließ-, Einscher-, Ausscher- und Aufteilungsmanöver. Eine mikroskopische Auswertung der Fahrmanöver wird anhand der Fahrtrajektorien durchgeführt, bevor im nächsten Kapitel die makroskopischen und systemweiten Auswirkungen der kooperativen Fahrfunktion anhand der Simulationsergebnisse diskutiert werden.

6.1 Grundlagen der modellprädiktiven Regelung

Um den Gesamtenergiebedarf für den Fahrzeugantrieb zu minimieren, wurde in zahlreichen Publikationen [121], [122], [123], [124] die Implementierung einer modellprädiktiven Regelung (MPR) mit einem linearen Zustandsraummodell untersucht. Diese Studien zeigen, dass diese Methode wirksam ist, um unnötige Beschleunigungs- und Verzögerungsmanöver zu reduzieren und somit insgesamt zu einer verbesserten Energieeffizienz beiträgt. Nach [121] kann ein solcher Ansatz mit optimierten Geschwindigkeitsprofilen den Energiebedarf eines Plug-In-Hybridfahrzeugs um bis zu 45 %, den eines batterieelektrischen Fahrzeugs um ca. 44 % und den eines verbrennungsmotorgetriebenen Fahrzeugs um ca. 35 %, reduzieren.
Das Grundprinzip der MPR ist im Anhang A.3.1 dargestellt. Ziel der MPR liegt darin, einen optimalen Stellgrößenverlauf zu ermitteln, der die Abweichung zwischen dem gewünschten Sollwertverlauf und dem prädizierten Verlauf der Regelgröße innerhalb des sogenannten Prädiktionshorizonts N_p unter Einhaltung aller Nebenbedingungen minimiert.
In jedem Berechnungsschritt wird lediglich der optimale Stellgrößenwert für den nächsten Zeitschritt an den Prozess weitergegeben, während die restlichen Werte des Stellgrößenverlaufs verworfen werden. In jedem folgenden Zeitschritt wird das Berechnungsverfahren erneut durchgeführt, wobei der Prädiktionshorizont um einen Zeitschritt verschoben wird. Dieses iterative Verfahren ermöglicht eine kontinuierliche Anpassung der Stellgröße an das dynamische Verhalten des Prozesses und führt dadurch zu einer optimierungsbasierten Prozesssteuerung.
Generell kann das lineare Zustandsraummodell einer MPR wie folgt formuliert werden:

$$\boldsymbol{x}(k+1) = \boldsymbol{A}\boldsymbol{x}(k) + \boldsymbol{B}\boldsymbol{u}(k) + \boldsymbol{G}\boldsymbol{w}(k) \tag{6.1}$$

$$\boldsymbol{y}(k) = \boldsymbol{C}\boldsymbol{x}(k) + \boldsymbol{v}(k) \tag{6.2}$$

Mit den Nebenbedingungen:

$$\boldsymbol{u}_{\mathbf{min}}(k) \leq \boldsymbol{u}(k) \leq \boldsymbol{u}_{\mathbf{max}}(k) \tag{6.3}$$

$$\boldsymbol{x}_{\mathbf{min}}(k) \leq \boldsymbol{x}(k) \leq \boldsymbol{x}_{\mathbf{max}}(k) \tag{6.4}$$

Für eine gegebene Zeit k wird das Optimierungsproblem über einen endlichen Prädiktionshorizont N_p gelöst. Hierbei sind $\boldsymbol{x}$, $\boldsymbol{u}$ und $\boldsymbol{y}$ die Zustands-, Stell- und Systemausgangsgrößen. $\boldsymbol{w}$ und $\boldsymbol{v}$ sind als Störgrößen definierte Prozess- und Messrauschen. $\boldsymbol{A}$, $\boldsymbol{B}$, $\boldsymbol{C}$ und $\boldsymbol{G}$ sind Systemzustandsmatrizen. Die Stell- und Zustandsgrößen, $\boldsymbol{u}$ und $\boldsymbol{x}$, sind beschränkt.
Die prädizierten Ausgangsgrößen hängen von den zu optimierenden Stellgrößen ab und die Abweichung zwischen den Ausgangsgrößen und der Referenztrajektorie $\boldsymbol{r}$ wird durch eine Kostenfunktion J quantifiziert. Es wird eine quadratische Formulierung verwendet:

$$J = \sum_{k=0}^{N_\mathrm{p}-1} (\boldsymbol{x}(k) - \boldsymbol{r}(k))^\mathrm{T} \cdot \boldsymbol{Q} \cdot (\boldsymbol{x}(k) - \boldsymbol{r}(k)) + \boldsymbol{u}(k)^\mathrm{T} \cdot \boldsymbol{R} \cdot \boldsymbol{u}(k) \tag{6.5}$$

wobei $\boldsymbol{Q}$ und $\boldsymbol{R}$ die Gewichtungsmatrizen sind.
Zur Verwendung des MPR-Algorithmus besteht der nächste Schritt darin, das energieeffiziente kooperative Fahrfunktionen als Optimierungsproblem zu formulieren. Die detaillierte Ausarbeitung dieser Thematik wird im folgenden Kapitel behandelt.

6.2 Zentralisierte kooperative Fahrfunktion für die Folgefahrt

Zur Ermöglichung einer ganzheitlichen Koordination vernetzter Fahrzeuge und um den Anforderungen gerecht zu werden, mehrere Fahrzeuggeschwindigkeitstrajektorien innerhalb eines einzigen Regelungsproblem zu optimieren und den Gesamtenergiebedarf für den Fahrzeugvortrieb zu reduzieren, wird zunächst die zentralisierte kooperative Fahrfunktion (engl. Centralized Cooperative Adaptive Cruise Control, C-CACC) anhand eines Folgefahrtszenarios, welches die Folgefahrt von Fahrzeugen auf dem gleichen Fahrstreifen umfasst, beschrieben.

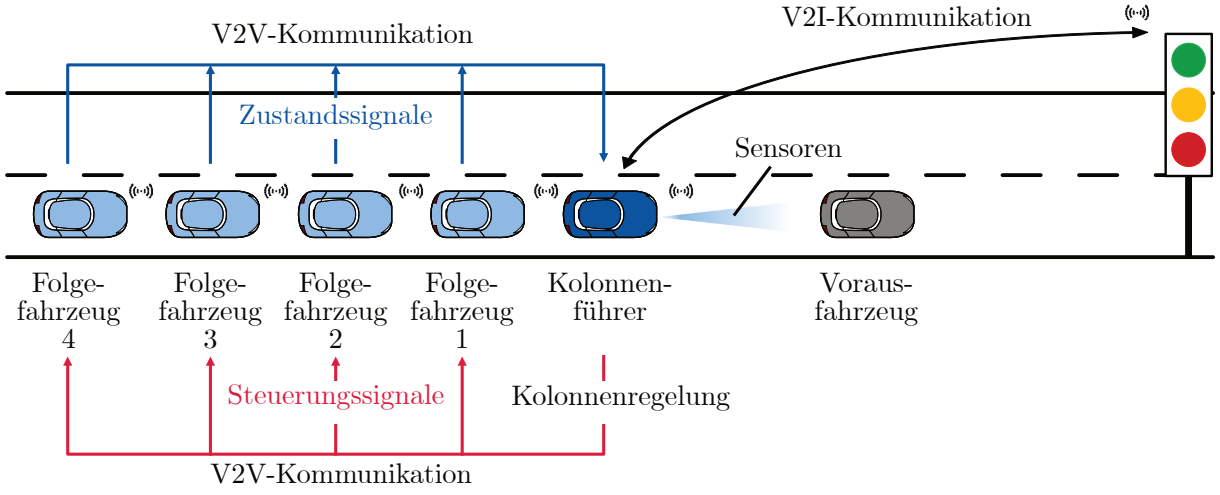

Abbildung 6.1: Schematische Darstellung der Kommunikationen bei der zentralisierten Kolonnenregelung mit einem Kolonnenführer und vier Folgefahrzeugen

Abbildung 6.1 zeigt die zentralisierte Kolonnenregelung, bei der fünf Kolonnenfahrzeuge einem vorausfahrenden Fahrzeug auf einer geraden Straße folgen und mehrere LSA passieren. Das Geschwindigkeitsprofil des vorausfahrenden Fahrzeugs ergibt sich aus der Verkehrssimulation und die Schaltzeiten der LSA basieren auf realen Messdaten.
Im Gegensatz zu konventionellen Kolonnenfahrten bei Lkw, bei denen häufig aerodynamische Vorteile durch dichtes Auffahren im Vordergrund stehen, verfolgt die zentralisierte Kolonnenregelung im urbanen Bereich eine andere Zielsetzung. Hierbei soll das Geschwindigkeitsprofil aller beteiligten Kolonnenfahrzeuge optimiert werden, um unnötige Beschleunigungs- und Verzögerungsmanöver zu reduzieren und somit den Gesamtenergiebedarf zu minimieren. Zu diesem Zweck wird ein linearer MPR-Algorithmus eingesetzt, um das Optimalsteuerungsproblem zu formulieren und zu lösen.

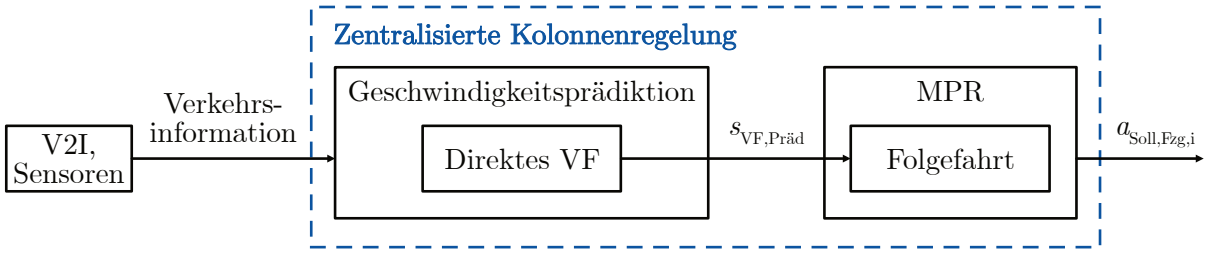

Abbildung 6.2: Struktur der zentralisierten Kolonnenregelung

Abbildung 6.2 stellt die Struktur der zentralisierten Kolonnenregelung dar, bei der die Verkehrsinformation sowohl aus der V2I-Kommunikation als auch von Sensoren für das Geschwindigkeitsprädiktionsmodell des direkten VFs gesammelt wird. Die prädizierte zurückzulegende Strecke des VFs $s_{\mathrm{VF,Präd}}$ wird im Anschluss an den MPR-Algorithmus weitergeleitet, mithilfe dessen die Geschwindigkeitsprofile für eine energieeffiziente Kolonnenfahrt generiert werden können. Dieser Algorithmus wird in den nachfolgenden Unterkapiteln näher erläutert.

6.2.1 Fahrzeuglängsdynamik

Zur Modellierung der Fahrzeuglängsdynamik wird eine lineare Zustandsraumdarstellung verwendet, welche die kinematische Beziehung zwischen zurückgelegter Strecke, Geschwindigkeit, Beschleunigung und Ruck berücksichtigt.
Für den Kolonnenführer (KF) enthält die Zustandsgröße $\boldsymbol{x_{KF}}$ die zurückgelegte Strecke s_{KF}, die Geschwindigkeit v_{KF}, die positive und negative Beschleunigung $a_{\mathrm{KF,pos}}$ und $a_{\mathrm{KF,neg}}$ sowie die gewünschte positive und negative Beschleunigung $a_{\mathrm{KF,soll,pos}}$ und $a_{\mathrm{KF,soll,neg}}$. Die Stellgröße $\boldsymbol{u_{KF}}$ besteht aus den positiven und negativen Rucks $j_{\mathrm{KF,pos}}$ und $j_{\mathrm{KF,neg}}$ des Fahrzeugs. Die prädizierte Fahrstrecke s_{VF} des VFs wird in der MPR als Teil der Nebenbedingung für die maximale Fahrstrecke des KFs verwendet.
Im Gegensatz zum KF wird bei den Folgefahrzeugen (FF) die erste Zustandsvariable durch den Abstand zum jeweiligen vorausfahrenden Fahrzeug d_{FF} ersetzt. Die prädizierte Geschwindigkeit des jeweils vorausfahrenden Fahrzeugs $v_{\mathrm{FF,VF}}$, welche Teil der Zustandsvariablen $\boldsymbol{x_{FF,VF}}$ ist, wird als Störgröße $\boldsymbol{G_{FF}} \cdot \boldsymbol{w_{FF}}$ in die MPR eingebunden. Das vorausfahrende Fahrzeug des ersten FFs entspricht dabei dem KF.
Das lineare Zustandsraummodell kann für KF und FF wie folgt formuliert werden:

Für KF:

$$\begin{gathered}\dot{\boldsymbol{x}}_{\mathbf{KF}} = \boldsymbol{A}_{\mathbf{KF}} \cdot \boldsymbol{x}_{\mathbf{KF}} + \boldsymbol{B}_{\mathbf{KF}} \cdot \boldsymbol{u}_{\mathbf{KF}} \\ \text{mit } \boldsymbol{x}_{\mathbf{KF}} = \begin{bmatrix} s_{\mathrm{KF}} \\ v_{\mathrm{KF}} \\ a_{\mathrm{KF,pos}} \\ a_{\mathrm{KF,neg}} \\ a_{\mathrm{KF,soll,pos}} \\ a_{\mathrm{KF,soll,neg}} \end{bmatrix}, \boldsymbol{u}_{\mathbf{KF}} = \begin{bmatrix} j_{\mathrm{KF,pos}} \\ j_{\mathrm{KF,neg}} \end{bmatrix}, \\ \boldsymbol{A}_{\mathbf{KF}} = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 1 & 0 & 0 \\ 0 & 0 & -\frac{1}{T_{\mathrm{a,besch}}} & 0 & \frac{1}{T_{\mathrm{a,besch}}} & 0 \\ 0 & 0 & 0 & -\frac{1}{T_{\mathrm{a,verz}}} & 0 & \frac{1}{T_{\mathrm{a,verz}}} \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}, \textit{und } \boldsymbol{B}_{\mathbf{KF}} = \begin{bmatrix} 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 1 & 0 \\ 0 & 1 \end{bmatrix}. \end{gathered} \tag{6.6}$$

Für FF:

$$\begin{gathered}\dot{\boldsymbol{x}}_{\mathbf{FF}} = \boldsymbol{A}_{\mathbf{FF}} \cdot \boldsymbol{x}_{\mathbf{FF}} + \boldsymbol{B}_{\mathbf{FF}} \cdot \boldsymbol{u}_{\mathbf{FF}} + \boldsymbol{G}_{\mathbf{FF}} \cdot \boldsymbol{w}_{\mathbf{FF}} \\ \text{mit } \boldsymbol{x}_{\mathbf{FF}} = \begin{bmatrix} d_{\mathrm{FF}} \\ v_{\mathrm{FF}} \\ a_{\mathrm{FF,pos}} \\ a_{\mathrm{FF,neg}} \\ a_{\mathrm{FF,soll,pos}} \\ a_{\mathrm{FF,soll,neg}} \end{bmatrix}, \boldsymbol{u}_{\mathbf{FF}} = \begin{bmatrix} j_{\mathrm{FF,pos}} \\ j_{\mathrm{FF,neg}} \end{bmatrix}, \boldsymbol{A}_{\mathbf{FF}} = \begin{bmatrix} 0 & -1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 1 & 0 & 0 \\ 0 & 0 & -\frac{1}{T_{\mathrm{a,besch}}} & 0 & \frac{1}{T_{\mathrm{a,besch}}} & 0 \\ 0 & 0 & 0 & -\frac{1}{T_{\mathrm{a,verz}}} & 0 & \frac{1}{T_{\mathrm{a,verz}}} \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}, \\ \boldsymbol{B}_{\mathbf{FF}} = \begin{bmatrix} 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \\ 1 & 0 \\ 0 & 1 \end{bmatrix}, \boldsymbol{G}_{\mathbf{FF}} = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}, \textit{und } \boldsymbol{w}_{\mathbf{FF}} = \boldsymbol{x}_{\mathbf{FF,VF}} = \begin{bmatrix} d_{\mathrm{FF,VF}} \\ v_{\mathrm{FF,VF}} \\ a_{\mathrm{FF,VF,pos}} \\ a_{\mathrm{FF,VF,neg}} \\ a_{\mathrm{FF,VF,soll,pos}} \\ a_{\mathrm{FF,VF,soll,neg}} \end{bmatrix}. \end{gathered} \tag{6.7}$$

$\boldsymbol{A}_{\mathbf{KF/FF}}$, $\boldsymbol{B}_{\mathbf{KF/FF}}$ und $\boldsymbol{G}_{\mathbf{FF}}$ sind dabei die Systemmatrizen. Eine Verzögerungszeit erster Ordnung mit den Zeitkonstanten $T_{\mathrm{a,besch}}$ und $T_{\mathrm{a,verz}}$ beschreibt die Übertragungsfunktion von gewünschter auf die tatsächliche Beschleunigung und Verzögerung.
Zur Formulierung der MPR-Problemstellung wird das kontinuierliche Zustandsraummodell mit einer Taktzeit von 1 s diskretisiert:

$$\begin{aligned} \boldsymbol{x}_{\mathbf{KF}}(k+1) &= \boldsymbol{A}_{\mathbf{KF}} \cdot \boldsymbol{x}_{\mathbf{KF}}(k) + \boldsymbol{B}_{\mathbf{KF}} \cdot \boldsymbol{u}_{\mathbf{KF}}(k) \\ \boldsymbol{x}_{\mathbf{FF}}(k+1) &= \boldsymbol{A}_{\mathbf{FF}} \cdot \boldsymbol{x}_{\mathbf{FF}}(k) + \boldsymbol{B}_{\mathbf{FF}} \cdot \boldsymbol{u}_{\mathbf{FF}}(k) + \boldsymbol{G}_{\mathbf{FF}} \cdot \boldsymbol{w}_{\mathbf{FF}}(k) \end{aligned} \tag{6.8}$$

Das zukünftige Fahrzeuglängsdynamikverhalten kann, ausgehend vom Zeitschritt k, in Abhängigkeit eines Stellgrößenverlaufs durch rekursive Verwendung der diskreten Zustandsraumgleichungen bestimmt werden.

6.2.2 Kostenfunktion

Zur Formulierung und Lösung des Optimierungsproblems wird eine quadratische Kostenfunktion J und der QP-Solver qpOASES [125] verwendet. Um die Ziele des Optimierungsproblems zu erreichen, nämlich die Reduzierung von Beschleunigungs- und Verzögerungsmanövern bei gleichzeitiger Verbesserung der Straßenbenutzung und Sicherheit, wird die Kostenfunktion, einschließlich der gewichteten

Kosten für Abweichungen von den Referenzzuständen und Stellgrößen, wie folgt definiert:

$$J = \sum_{n=1}^{n_{\mathrm{Fzg,ges}}} \sum_{j=0}^{N_{\mathrm{p}}-1} (\boldsymbol{x}_{\mathbf{n}}(k+j) - \boldsymbol{r}_{\mathbf{n}}(k+j))^{\mathrm{T}} \cdot \boldsymbol{Q}_{\mathbf{n}} \cdot (\boldsymbol{x}_{\mathbf{n}}(k+j) - \boldsymbol{r}_{\mathbf{n}}(k+j)) + \boldsymbol{u}_{\mathbf{n}}^{\mathrm{T}}(k+j) \cdot \boldsymbol{R}_{\mathbf{n}} \cdot \boldsymbol{u}_{\mathbf{n}}(k+j)$$

$$\text{mit } \boldsymbol{Q}_{\mathbf{n}} = \begin{bmatrix} Q_{\mathrm{s,KF/d,FF}} & 0 & 0 & 0 & 0 & 0 \\ 0 & Q_{\mathrm{v}} & 0 & 0 & 0 & 0 \\ 0 & 0 & Q_{\mathrm{besch}} & 0 & 0 & 0 \\ 0 & 0 & 0 & Q_{\mathrm{verz}} & 0 & 0 \\ 0 & 0 & 0 & 0 & Q_{\mathrm{besch}} & 0 \\ 0 & 0 & 0 & 0 & 0 & Q_{\mathrm{verz}} \end{bmatrix}, \boldsymbol{R}_{\mathbf{n}} = \begin{bmatrix} Q_{\mathrm{ruck,pos}} & 0 \\ 0 & Q_{\mathrm{ruck,neg}} \end{bmatrix} \tag{6.9}$$

Der Index j bezeichnet die prädizierten Schritte zum Zeitpunkt k, während der Index n die Fahrzeugnummer angibt und als $n_{\mathrm{KF,FF1,...,FF4}} = 1, 2, ..., 5$ definiert ist. Das Optimierungsproblem wird zu jedem Zeitpunkt k während der Simulation unter Verwendung aktueller Informationen über die Fahrzeugzustände gelöst. Die Gesamtkosten J für alle Fahrzeuge werden anhand der Kostenfunktion Gl. 6.9 berechnet. $\boldsymbol{x}$ ist die zu optimierende Zustandsgrößentrajektorie und $\boldsymbol{r}$ ist die Referenztrajektorie. Die Gewichtungsmatrix $\boldsymbol{Q}$ bestraft die Abweichung zwischen den prädizierten Zuständen $\boldsymbol{x}$ und den Referenzzuständen $\boldsymbol{r}$. Gleichzeitig bestraft die Gewichtungsmatrix $\boldsymbol{R}$ die Stellgrößentrajektorie $\boldsymbol{u}$. Die Diagonaleinträge der Gewichtungsmatrix sind die Gewichtung der zurückzulegenden Strecke von KF oder Abstand von FF $Q_{\mathrm{s,KF/d,FF}}$, der Geschwindigkeit Q_{v}, der Beschleunigung und Verzögerung $Q_{\mathrm{besch/verz}}$ sowie des Rucks $Q_{\mathrm{ruck,pos/neg}}$.
Die Referenzfahrzeugposition des KFs und der Referenzabstand des FFs werden mit der Position des vorausfahrenden Fahrzeugs $s_{\mathrm{VF}}(k)$ und der prädizierten Geschwindigkeit des Kolonnenfahrzeugs $v_{\mathrm{KF/FF}}(k)$ berechnet. d_{ref} und $t_{\mathrm{d,ref}}$ sind jeweils der Referenzabstand und -zeitabstand. Die Referenzgeschwindigkeit ist die maximal zulässige Geschwindigkeitsbegrenzung v_{lim}, und die Referenzbeschleunigung und -ruck sind jeweils $a_{\mathrm{ref}} = 0\ \mathrm{m/s^2}$ bzw. $j_{\mathrm{ref}} = 0\ \mathrm{m/s^3}$.

$$\boldsymbol{r}_{\mathbf{KF}}(k) = \begin{bmatrix} s_{\mathrm{VF}}(k) - d_{\mathrm{ref}} - t_{\mathrm{d,ref}} \cdot v_{\mathrm{KF}}(k) \\ v_{\mathrm{lim}}(k) \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}, \boldsymbol{r}_{\mathbf{FF}}(k) = \begin{bmatrix} d_{\mathrm{ref}} + t_{\mathrm{d,ref}} \cdot v_{\mathrm{FF}}(k) \\ v_{\mathrm{lim}}(k) \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix} \tag{6.10}$$

Diese Kostenfunktion zielt nicht direkt auf die Minimierung des Energiebedarfs ab. Dennoch kann gemäß den Studien von [122] und [30] durch entsprechende Gewichtungen in der Kostenfunktion eine Reduktion unnötiger Beschleunigungs- und Verzögerungsmanöver von einzelnen Fahrzeug erreicht werden. Durch die Vermeidung dieser überflüssigen doppelten Energieumwandlungen kann der Energiebedarf reduziert werden, während gleichzeitig ein fließender Verkehr gewährleistet wird.

6.2.3 Nebenbedingungen

Bei einem beschränkten Optimierungsproblem haben realisierbare Grenzen von den Zustands- und Stellgrößen einen wichtigen Einfluss auf die Lösung. Physikalische Begrenzungen des Sicherheitsabstands zwischen Kolonnenfahrzeugen, der Geschwindigkeitslimitierung und der Antriebsleistung sollten in den oberen und unteren Grenzen der Zustands- und Stellgrößen des Optimierungsproblems

berücksichtigt werden.
Die maximal zulässige Fahrstrecke des KFs wird basierend auf der prädizierten Position des VFs bestimmt. Unter der Verwendung des Prädiktionsmodells des VKs (Kapitel 5) wird deren Fahrstrecke $s_{\mathrm{VF}}(k)$ für den gesamten Prädiktionshorizont vorhergesagt. Die maximal zulässige Fahrstrecke des KFs wird mit einem konstanten Mindestsicherheitsabstand d_{min}, der prädizierten KF-Geschwindigkeit $v_{\mathrm{KF}}(k)$ und einem konstanten Zeitabstand $t_{\mathrm{d,min}}$ berechnet. Die minimal zulässige Fahrstrecke des KFs ist die aktuelle zurückgelegte Strecke $s_{\mathrm{KF,akt}}$, somit wird das Rückwärtsfahren nicht berücksichtigt:

$$s_{\mathrm{KF}}(k) \leq s_{\mathrm{VF}}(k) - (d_{\mathrm{min}} + t_{\mathrm{d,min}} \cdot v_{\mathrm{KF}}(k)) + \epsilon_{\mathrm{max}}(k) \cdot d_{\mathrm{weich}} \tag{6.11a}$$

$$s_{\mathrm{KF}} \geq s_{\mathrm{KF,akt}} \tag{6.11b}$$

Durch die Einführung der Schlupfvariablen $\epsilon \geq 0$ ermöglicht die sogenannte weiche Nebenbedingung dem Optimierungsproblem, die harte Nebenbedingung bei Nichtdurchführbarkeit um $\epsilon_{\mathrm{max}}(k) \cdot d_{\mathrm{weich}}$ zu erweitern, um eine gültige Lösung zu finden. [126] Zum Zweck der Minimierung des Einflusses der weichen Nebenbedingungen auf das Optimierungsproblem, wird die Schlupfvariable in der Kostenfunktion mit einem vergleichsweise großen Faktor gewichtet, sodass die Nebenbedingungen nur im Falle der Nichtdurchführbarkeit erweitert werden kann (vgl. Gl. 6.13).
Analog zum KF wird der maximal und minimal zulässige FF-Abstand $d_{\mathrm{FF}}(k)$ durch die konstanten maximalen und minimalen Abständen d_{max} und d_{min}, der prädizierten FF-Geschwindigkeit $v_{\mathrm{FF}}(k)$ und den konstanten maximalen und minimalen Zeitabständen $t_{\mathrm{d,max}}$ und $t_{\mathrm{d,min}}$ berechnet:

$$d_{\mathrm{FF}}(k) \leq d_{\mathrm{max}} + t_{\mathrm{d,max}} \cdot v_{\mathrm{FF}}(k) \tag{6.12a}$$

$$d_{\mathrm{FF}}(k) \geq d_{\mathrm{min}} + t_{\mathrm{d,min}} \cdot v_{\mathrm{FF}}(k) - \epsilon_{\mathrm{min}}(k) \cdot d_{\mathrm{weich}} \tag{6.12b}$$

Auf diese Weise werden die Abstände zwischen Kolonnenfahrzeugen in Abhängigkeit von deren eigenen Geschwindigkeit begrenzt. Die maximalen und minimalen Zeitabstände $t_{\mathrm{d,max/min}}$ ermöglichen es der MPR, eine flexible Entscheidung über den Abstand zwischen Fahrzeugen innerhalb der Begrenzung zu treffen. Der Vorteil ist, dass das Optimierungsproblem eine Lösung mit einem optimalen Verhältnis zwischen Fahrzeugbeschleunigung bzw. Energieeffizienz und Kolonnenstabilität finden kann.
Sowohl KF als auch FF haben eine weiche Begrenzung für die zurückgelegte Strecke bzw. den Abstand. Diese ist insbesondere bei niedrigen Geschwindigkeiten erforderlich, denn der Unterschied zwischen dem maximal und minimal zulässigen Abstand zwischen den Fahrzeugen ist gering. Die Schlupfvariable ermöglicht es der MPR, die Beschränkung zu erweitern, um eine Lösung zu finden, bevor das Optimierungsproblem nicht mehr lösbar wird.

Basierend auf diesem Zusammenhang kann die Kostenfunktion zum Zeitpunkt k wie folgt formuliert werden:

$$\begin{aligned} J = & \sum_{n=1}^{n_{\mathrm{Fzg,ges}}} \sum_{j=0}^{N_{\mathrm{p}}-1} (\boldsymbol{x}_{\mathbf{n}}(k+j) - \boldsymbol{r}_{\mathbf{n}}(k+j))^{\mathrm{T}} \cdot \boldsymbol{Q}_{\mathbf{n}} \cdot (\boldsymbol{x}_{\mathbf{n}}(k+j) - \boldsymbol{r}_{\mathbf{n}}(k+j)) \\ & + \boldsymbol{u}_{\mathbf{n}}^{\mathrm{T}}(k+j) \cdot \boldsymbol{R}_{\mathbf{n}} \cdot \boldsymbol{u}_{\mathbf{n}}(k+j) + \sum_{n=1}^{n_{\mathrm{Fzg,ges}}} \sum_{j=0}^{N_{\mathrm{p}}-1} (\boldsymbol{q}_{\boldsymbol{\epsilon}} \cdot \boldsymbol{\epsilon}_{\mathbf{n}}(k+j)), \\ & \text{mit } \boldsymbol{\epsilon} = \begin{bmatrix} \epsilon_{\max} & 0 \\ 0 & \epsilon_{\min} \end{bmatrix} \end{aligned} \tag{6.13}$$

Dabei ist $\boldsymbol{q}_{\boldsymbol{\epsilon}}$ der Gewichtungsfaktor der Schlupfvariablen $\boldsymbol{\epsilon}$ mit $\boldsymbol{q}_{\boldsymbol{\epsilon}} \gg \boldsymbol{Q}_{\mathbf{n}}$, sodass die Nebenbedingungen nur dann erweitert werden, wenn das Optimierungsproblem mit den harten Nebenbedingungen nicht mehr lösbar ist.
Wie bereits erwähnt, soll bei diesem Optimierungsproblem nicht nur der Fahrzeugabstand, sondern auch die Geschwindigkeit begrenzt werden. Die minimale Fahrzeuggeschwindigkeit $v_{\min}$ wird auf 0 km/h festgelegt. Die maximal zulässige Geschwindigkeit ist definiert als die straßenzugelassene Geschwindigkeitsgrenze v_{lim} mit einem zusätzlichen Toleranzwert v_{Toleranz}:

$$v_{\min} \leq v_{\mathrm{Fzg}}(k) \leq v_{\mathrm{lim}} + v_{\mathrm{Toleranz}} \tag{6.14}$$

Unter Berücksichtigung der physikalischen Grenzen der Fahrzeugantriebsleistung, der Kapazität des Bremssystems und des Komforts für den Fahrgast sind die gewünschte und tatsächliche positive und negative Beschleunigung auf 2 m/s^2 und -8 m/s^2 begrenzt. Die Steuergrößen, positiver und negativer Ruck, sind auf 5 m/s^3 bzw. -5 m/s^3 begrenzt.

6.2.4 Prädiktionshorizont

Frühere Forschungsergebnisse von [30] haben bei einem ähnlichen Optimierungsproblem bereits gezeigt, dass der Prädiktionshorizont einen großen Einfluss auf den Energiebedarf eines einzelnen Fahrzeugs hat. Nach [30] steigt die Kraftstoffeinsparung mit einem längeren Prädiktionshorizont bei einer perfekten Geschwindigkeitsprädiktion des VFs. In der Realität nimmt jedoch die Genauigkeit eines Prädiktionsmodells mit einem längeren Prädiktionshorizont, wie im Abschnitt 5.3.3 beschreiben, ab, wodurch auch die Ergebnisse des Optimierungsproblems mit MPR beeinflusst werden. Außerdem steigt der Rechenaufwand mit einem längeren Prädiktionshorizont exponentiell an. Um die Auswirkungen des Prädiktionshorizonts auf die Gesamtenergieeffizienz mehrerer Fahrzeuge in einer Kolonne zu analysieren, werden in dieser Arbeit die Prädiktionshorizonte $N_{\mathrm{p}} = 5\,\mathrm{s}$, $10\,\mathrm{s}$ und $15\,\mathrm{s}$ untersucht. Die Ergebnisse werden in folgenden Unterkapitel vorgestellt.

6.2.5 Energieeinsparpotenzial im Folgefahrtszenario

Zur Analyse des Energiebedarfs aller Fahrzeuge in einer Kolonne in Abhängigkeit von den Parametern der MPR, werden Simulationen für das Folgefahrtszenario durchgeführt, wobei eine geradlinige und einspurige Straße in SUMO modelliert wird. Ein VF folgt einem Geschwindigkeitsprofil, das auf

realen Messdaten basiert, während eine Kolonne von fünf Fahrzeugen diesem VF folgt.
Als Referenz werden die Fahrzeuge mit dem in SUMO implementierten IDM-Algorithmus mit denselben Parametereinstellungen wie die MPR ausgestattet und folgen demselben VF. Das verwendete Fahrzeugmodell ist das in SUMO hinterlegte Modell, welches einen Energiebedarf gemäß des WLTC von 15,5 kWh/100 km aufweist.
Im Hinblick auf die Nebenbedingungen des MPR-Algorithmus kommen zwei unterschiedliche Prädiktionsmodelle zum Einsatz: die perfekte Geschwindigkeitsprädiktion sowie das in Abschnitt 5 beschriebene LSTM-Prädiktionsmodell, das zur Vorhersage der Geschwindigkeit des VFs dient. Diese dienen der Untersuchung des Einflusses von Prädiktionsfehlern auf den MPR-Algorithmus. Darüber hinaus werden Prädiktionshorizonte N_p von 5 s, 10 s und 15 s sowie Gewichtungsfaktoren für Beschleunigung und Verzögerung, Q_besch und Q_verz, im Bereich von 0,05 bis 50 berücksichtigt, um deren Auswirkungen auf den Energiebedarf zu bestimmen. Die grundlegenden Parameter für diese Simulationen sind in Tabelle A.3.1 festgelegt.
Tabelle 6.1 zeigt beispielhaft den simulierten Energiebedarf sowohl des KFs als auch der Folgefahrzeuge FF1 bis FF4. Es ist zu beobachten, dass der Energiebedarf mit dem Einsatz des IDMs vom KF bis zum FF3 ansteigt, während das vierte Folgefahrzeug einen geringfügig niedrigeren Energiebedarf als das FF3 aufweist. Der durchschnittliche Energiebedarf beträgt 9,19 kWh/100 km. Diese Simulationsergebnisse des IDM-Algorithmus dienen als Referenz zur Bewertung des MPR-Algorithmus.

Tabelle 6.1: Simulierter Energiebedarf mit unterschiedlichen Prädiktionshorizonten und Prädiktionsmodellen

Fahrzeug	Energiebedarf in kWh/100 km						
	IDM	N_p=5 s		N_p=10 s		N_p=15 s	
	Ref.	Perf. Präd.	LSTM	Perf. Präd.	LSTM	Perf. Präd.	LSTM
KF	9,10	8,61	8,80	8,40	8,86	8,17	8,43
FF 1	9,17	8,71	8,85	8,37	8,61	8,21	8,36
FF 2	9,21	8,77	8,95	8,38	8,63	8,17	8,29
FF 3	9,23	8,84	8,99	8,41	8,62	8,15	8,25
FF 4	9,22	8,89	9,11	8,44	8,61	8,14	8,23
Durchschnitt	9,19	8,76	8,94	8,40	8,67	8,17	8,31
Energieeinsparpotenzial	-	-4,68%	-2,72%	-8,60%	-5,66%	-11,10%	-9,58%

Zur ausschließlichen Bewertung der Auswirkungen unterschiedlicher Prädiktionshorizonte auf den MPR-Algorithmus werden zuerst die Simulationsergebnisse mit perfekter Geschwindigkeitsprädiktion verglichen. Im Vergleich zum IDM-Algorithmus führt die MPR mit einem Prädiktionshorizont von 5 s, 10 s und 15 s zu einem geringeren durchschnittlichen Energiebedarf von 8,76, 8,40 und 8,17 kWh/100 km, was Einsparungen von 4,68 %, 8,60 % bzw. 11,10 % entspricht.
Bei der Betrachtung derselben Fahrzeugposition in einer Kolonne mit unterschiedlichen Prädiktionshorizonten lässt sich erkennen, dass der Energiebedarf mit zunehmendem Prädiktionshorizont abnimmt. Dies entspricht den Erwartungen, da die MPR dazu befähigt ist, die Geschwindigkeitstrajektorien aller Fahrzeuge weiter in die Zukunft zu planen, wenn der Prädiktionshorizont größer ist.

Das Verhalten von Beschleunigung, Geschwindigkeit und Abstand beim KF aus Simulationen mit einem Prädiktionshorizont von 5 s und 15 s sind in Abbildung 6.3a dargestellt. Wenn die Beschleunigungs- und Verzögerungsphase des VFs frühzeitig vorhergesagt wird, kann die MPR effizientere Beschleunigungs- und Verzögerungsmanöver planen. Dementsprechend wird erwartet, dass der Energiebedarf der Fahrzeuge bei einem längeren Prädiktionshorizont geringer ist. Diese Annahme wird beim Vergleich der Beschleunigungs- und Geschwindigkeitstrajektorien in Abbildung 6.3a bestätigt.

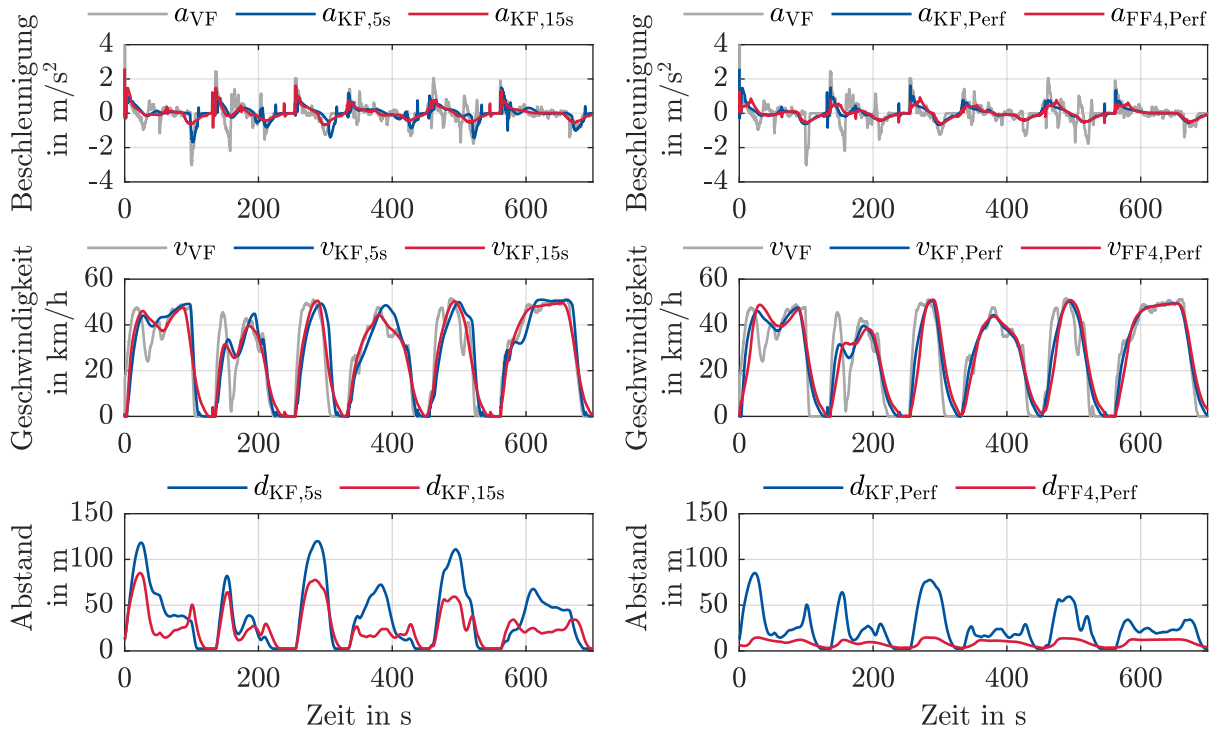

(a): Fahrzeugzustände bei $N_p = 5$ s und 15 s **(b):** Fahrzeugzustände innerhalb einer Kolonne

Abbildung 6.3: Vergleich der Beschleunigung, der Geschwindigkeit und des Abstands von Fahrzeugen mit: (a) $N_p = 5$ s und 15 s, (b) KF und FF4 bei $N_p = 15$ s

Ein ähnliches Verhalten zeigt sich auch bei der Gegenüberstellung von MPR-Ergebnissen aller Fahrzeuge in einer Kolonne mit demselben Prädiktionshorizont, d. h. der Energiebedarf vom KF bis FF4 nimmt annähend ab. Abbildung 6.3b stellt die Beschleunigung, Geschwindigkeit und den Abstand von KF und FF4 mit einem Prädiktionshorizont von 15 s dar. Es lässt sich beobachten, dass das Beschleunigungs- und Geschwindigkeitsverhalten des FF4 weniger sprunghaft ist als die des KFs, das auf eine stabilere Fahrweise von FF4 hinweist und folglich einen geringeren Energiebedarf impliziert. Um den Einfluss der Prädiktionsfehler auf den MPR-Algorithmus zu analysieren, kann der Energiebedarf (siehe Tabelle 6.1) unter Berücksichtigung des gleichen Prädiktionshorizonts sowohl mit perfekter Geschwindigkeitsprädiktion als auch mit dem LSTM-Prädiktionsmodell verglichen werden. Es lässt sich feststellen, dass der Energiebedarf aller Fahrzeuge bei einer perfekten Geschwindigkeitsprädikition geringer ausfällt als bei Anwendung des LSTM-Prädiktionsmodells. Beispielsweise resultiert bei einem Prädiktionshorizont von 15 s und einer perfekten Geschwindigkeitsprädiktion ein durchschnittlicher Energiebedarf von 8,18 kWh/100 km und ein Energieeinsparpotenzial von 11,10 %. Im Gegensatz dazu beträgt der Energiebedarf mit dem LSTM-Prädiktionsmodell 8,31 kWh/100 km, was einem Energieeinsparpotenzial von 9,58 % entspricht. Daraus lässt sich ableiten, dass Un-

genauigkeiten in der Prädiktion die Effektivität des MPR-Algorithmus reduzieren.
Abbildung 6.4a bietet eine Visualisierung dieses Effekts durch den Vergleich der Trajektorien des KFs von Beschleunigung, Geschwindigkeit und Abstand, sowohl mit perfekter Geschwindigkeitsprädiktion als auch mit dem LSTM-Prädiktionsmodell.

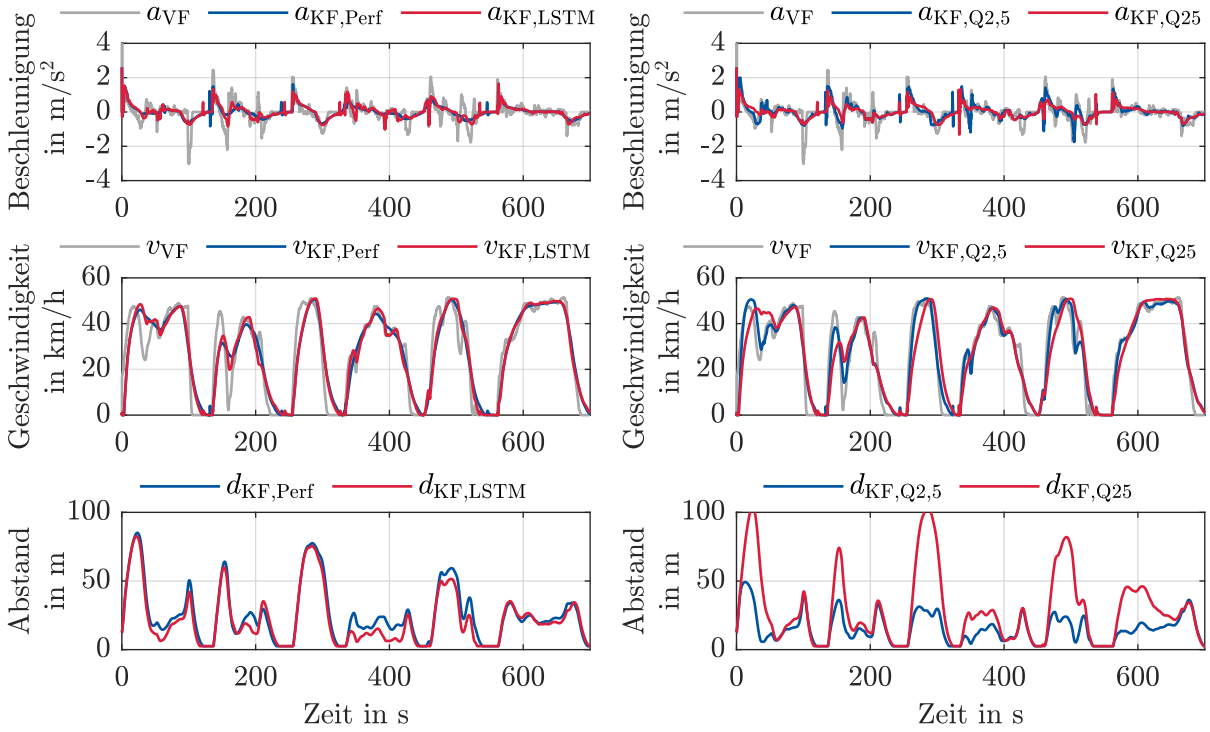

(a): Fahrzeugzustände mit Prädiktionsmodell **(b):** Fahrzeugzustände bei $q_{\text{Besch/Verz}} = 2{,}5$ und 25

Abbildung 6.4: Vergleich der Beschleunigung, Geschwindigkeit und des Abstands von KF mit: (a) perfekter Prädiktion und dem LSTM-Modell bei $N_\text{p} = 15$ s, (b) $Q_\text{besch} = Q_\text{verz} = 2{,}5$ und $Q_\text{besch} = Q_\text{verz} = 25$ bei $N_\text{p} = 15$ s

Es wird deutlich, dass die Amplituden sowohl des Beschleunigungs- als auch des Geschwindigkeitsverlaufs bei perfekter Geschwindigkeitsprädiktion niedriger ausfallen als beim LSTM-Prädiktionsmodell. Die Ungenauigkeit der LSTM-Prädiktion tritt häufig während Geschwindigkeitsveränderungen auf, beispielsweise zwischen den 450 und 540 s der Simulation (vgl. Abbildung 6.5). Das LSTM- Prädiktionsmodell prädiziert zunächst, dass das VF beschleunigen wird. Das auftretende Verzögerungsverhalten des VFs bei 460 s während der Beschleunigungsphase kann ursprünglich nicht vorhergesagt werden. Die MPR plant zuerst, mit hoher Beschleunigung auf eine höhere Geschwindigkeit zu fahren. Sobald das Prädiktionsmodell das Verzögerungsverhalten prädizieren kann, ändert die MPR plötzlich die geplante Trajektorie von Beschleunigung auf Verzögerung mit einem höheren Wert, um den Sicherheitsabstand zu gewährleisten. Dies ist der Grund für die häufige Änderung der Beschleunigung und die damit einhergehende Schwankung der Geschwindigkeit.
Dennoch kann das Optimierungsproblem mit dem MPR-Algorithmus stets gelöst werden, auch bei ungenauer Prädiktion, was darauf hindeutet, dass die Ungenauigkeit des LSTM-Prädiktionsmodells nicht zur Unlösbarkeit des Optimierungsproblems führt.
Der Energiebedarf eines Fahrzeugs unterliegt nicht nur der Beeinflussung durch das Prädiktionsmodell und den Prädiktionshorizont, sondern wird auch signifikant von den Gewichtungsfaktoren der

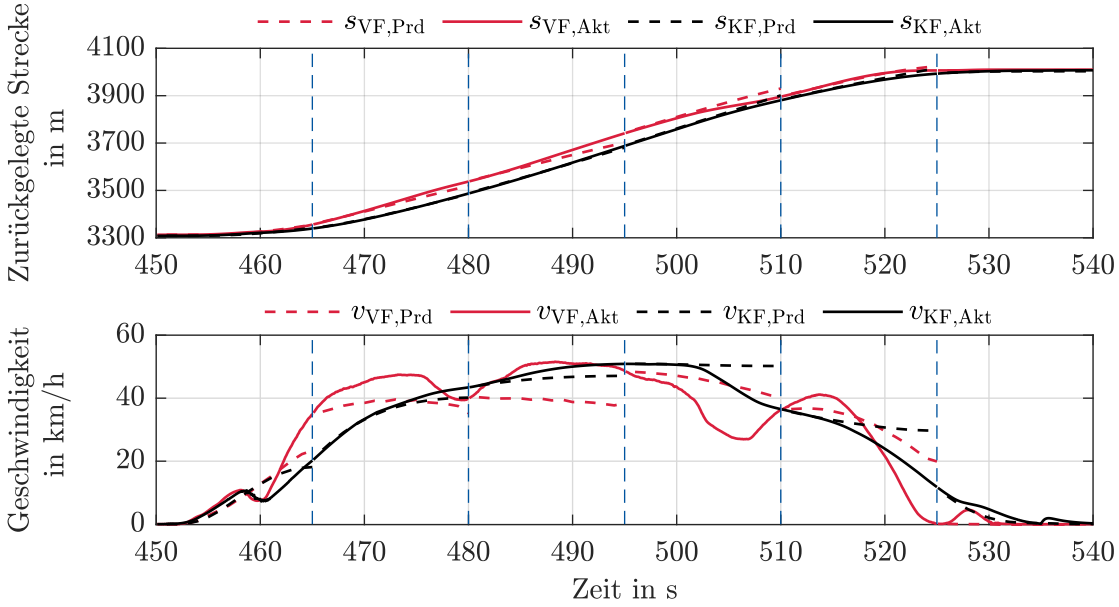

Abbildung 6.5: Prädizierte und aktuelle zurückgelegte Strecke und Geschwindigkeit von VF und KF bei N_p=15 s und Q_{besch}=Q_{verz}=15

Zustands- und Stellgrößen in der Kostenfunktion bestimmt, insbesondere von den Gewichtungsfaktoren für Beschleunigung und Verzögerung. Bei einer Einstellung der Gewichtungsfaktoren Q_{besch} = Q_{verz} = 2,5 liegt der durchschnittliche Energiebedarf bei 8,46 kWh/100 km. Eine Erhöhung dieser Werte auf 25 führt zu einem geringeren durchschnittlichen Energiebedarf von 8,28 kWh/100 km. Die Gewichtungsfaktoren für Beschleunigung und Verzögerung werden hierbei zur Bewertung gleichgesetzt, obgleich diese prinzipiell für verschiedene Optimierungsziele auf unterschiedliche Werte eingestellt werden könnten.

Die in Gleichung 6.9 formulierte Kostenfunktion sieht bei hohen Gewichtungsfaktoren für Beschleunigung und Verzögerung entsprechend hohe Strafen für diese Zustände vor. Um die Gesamtkosten zu minimieren, tendiert daher die Lösung des Optimierungsproblems zu niedrigeren Werten für Beschleunigung und Verzögerung. Dies wird in Abbildung 6.4b deutlich, welche Beschleunigung, Geschwindigkeit und Abstand des KFs unter verschiedenen Gewichtungsfaktoren darstellt. So zeigt die Beschleunigungstrajektorie aus der Simulation mit Q_{besch} = Q_{verz} = 2,5 eine höhere Amplitude als diejenige aus der Simulation mit Q_{besch} = Q_{verz} = 25. Infolgedessen beschleunigt das Fahrzeug schneller, erreicht höhere Geschwindigkeiten und hält einen geringeren Abstand zum vorausfahrenden Fahrzeug.

Obwohl der Energiebedarf durch eine Erhöhung des Gewichtungsfaktors für Beschleunigung und Verzögerung reduziert werden kann, werden die Abstände zwischen den Kolonnenfahrzeuge gleichzeitig vergrößert. Aus diesem Grund kann der Gewichtungsfaktor nicht unbegrenzt erhöht werden. Die Simulationsergebnisse für verschiedene Prädiktionshorizonte von 5 s, 10 s und 15 s sowie diverse Gewichtungsfaktoren sind in Abbildung 6.6 zusammengefasst.

Die erzielten Simulationsergebnisse zeigen eindeutige Tendenzen bei unterschiedlichem Prädiktionshorizont. Bei einem N_p = 5 s zeigt sich, dass eine Erhöhung des Gewichtungsfaktors Q_{besch} und Q_{verz} von 0,05 auf 50 zu einer signifikanten Reduktion des durchschnittlichen Energiebedarfs von 10,75 auf 8,11 kWh/100 km führt. Gleichzeitig reduziert sich die lokale Verkehrsdichte sehr deutlich

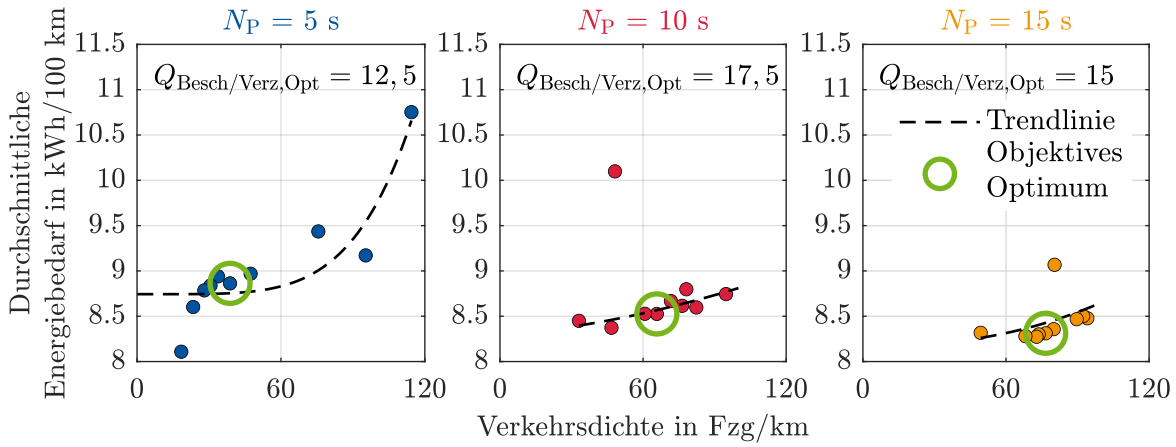

Abbildung 6.6: Durchschnittlicher Energiebedarf und durchschnittliche Verkehrsdichte bei unterschiedlichen MPR-Parametern

von 114 auf 18 Fahrzeuge pro Kilometer.

Wenn der Prädiktionshorizont auf 10 s erhöht wird, führt eine äquivalente Anpassung der Gewichtungsfaktoren zu einer Reduktion der Fahrzeugdichte von 95 auf 33 Fahrzeuge pro Kilometer und gleichzeitig zu einer Senkung des Energiebedarfs von 10,10 auf 8,37 kWh/100 km. Mit Berücksichtigung beider Kriterien erscheint ein Gewichtungsfaktor von 17,5 als ein ausgewogener Kompromiss für das untersuchte Verkehrsszenario.

Bei einer weiteren Erhöhung des Prädiktionshorizonts auf 15 s führt die Erhöhung des Gewichtungsfaktors von 0,05 auf 50 zu einer Reduktion des durchschnittlichen Energiebedarfs von 9,07 auf 8,27 kWh/100 km. Diese Einstellung im Vergleich zu den Ergebnissen bei einem Prädiktionshorizont von 10 s führt nicht zu einer signifikanten Senkung der Verkehrsdichte. Für dieses Verkehrsszenario wird ein Gewichtungsfaktor von 15 als guter Kompromiss ausgewählt.

Weiterhin verdeutlichen die in Abbildung 6.6 dargestellten Ergebnisse, dass die maximale durchschnittliche Verkehrsdichte bei einem Prädiktionshorizont von 5 s mit 114 Fahrzeugen pro Kilometer über den Werten von 95 bzw. 94 Fahrzeugen pro Kilometer bei einem Prädiktionshorizont von 10 s bzw. 15 s liegt. Dies kann dadurch erklärt werden, dass mit zunehmendem Prädiktionshorizont die Lösung des Optimierungsproblems näher am Referenzwert liegt. Bei kürzerem Prädiktionshorizont tendiert die Lösung dazu, die obere oder untere Grenze anzustreben, was in diesem Fall bedeutet, dass der Fahrzeugabstand den Minimalwert erreicht.

Die Analyse der Simulationsergebnisse lässt darauf schließen, dass die zentralisierte Kolonnenregelung Fahrzeugen das Fahren mit reduziertem Energiebedarf und geringerem Abstand auf geraden Strecken erlaubt. Diese Technologie bildet die Grundlage zur einheitlichen Koordinierung weiterer Fahrmanöver im städtischen Bereich. Das kooperative Fahrmanövermanagement wird im folgenden Kapitel detailliert erläutert.

6.3 Kooperatives Fahrmanövermanagement

Im urbanen Bereich können aufgrund der unterschiedlichen Fahrziele und Fahrverhaltensweisen sowie des Schaltprogramms der LSA deutlich komplexere Fahrszenarien als die reine Folgefahrt auftreten.

Diese Situationen können in verschiedene Manöverkategorien wie Aufschließen, Ein- und Ausscheren sowie Aufteilung unterteilt werden. Abbildung 6.7 veranschaulicht die erweiterte Struktur der zentralisierten Kolonnenregelung, die durch ein Managementsystem für Fahrmanöver ergänzt wird.

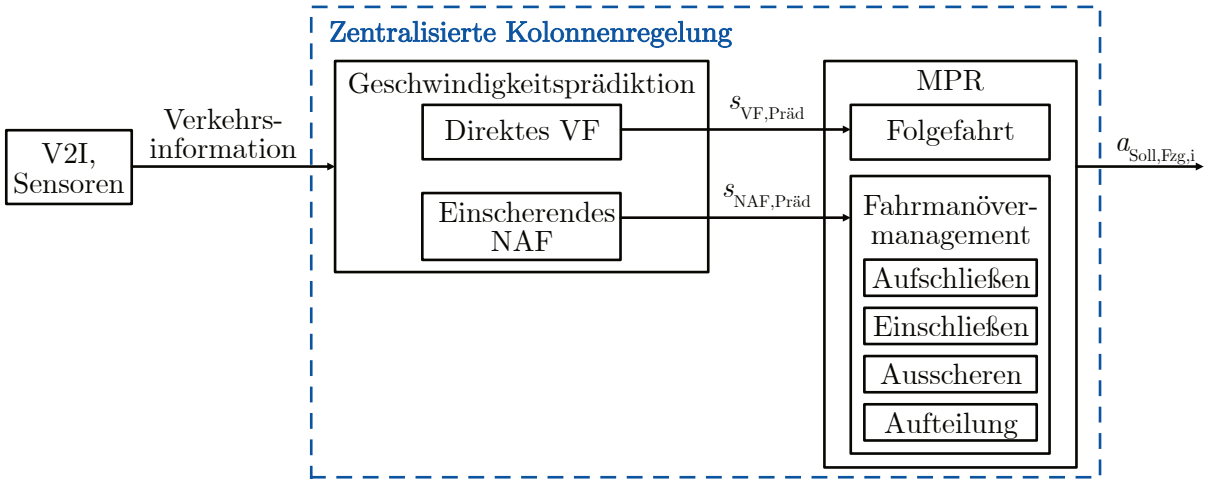

Abbildung 6.7: Struktur der zentralisierten Kolonnenregelung inkl. Fahrmanövermanagement

Hierbei kommt das Prädiktionsmodell für den Fahrstreifenwechsel zum Einsatz. Die prädizierte zurückzulegende Strecke des einscherenden NAFs wird an das Fahrmanövermanagement weitergeleitet. Basierend auf dem zuvor beschriebenen Basisszenario können weitere Fahrmanöver in das Optimierungsproblem integriert, koordiniert und durchgeführt werden. Diese Erweiterung wird in den nachfolgenden Unterkapiteln als kooperatives Fahrmanövermanagement erläutert.

6.3.1 Aufschließen

Ein häufig anzutreffendes Fahrmanöver ist das Aufschließen, bei welchem ein weiteres Fahrzeug der Kolonne auf demselben Fahrstreifen von hinten beitritt. Um diese Fahrmanöver kooperativ zu koordinieren, gelten folgende Grundvoraussetzungen:

- Das aufschließende Fahrzeug ist V2V-Kommunikationsfähig, welches auch automatisiertes Umgebungsfahrzeug (AUF) genannt wird.
- Das aufschließende Fahrzeug befindet sich mit der Kolonne auf demselben Fahrstreifen.
- Die maximale Anzahl an Fahrzeugen in der Kolonne wurde noch nicht erreicht.

Umgesetzt wird dieses Verhalten wie schematisch in Abbildung 6.8 dargestellt. Der gezeigte Ausgangszustand (Schritt 0) besteht in einer Kolonne aus zwei Fahrzeugen (KF und FF1) und einem AUF. Ausgehend vom AUF wird eine Anfrage an den KF der direkt vorausfahrenden Kolonne für die Möglichkeit des Aufschließens geschickt (Schritt 1). Ab diesem Moment wird das Fahrzeug durchgehend als aufschließendes Fahrzeug (AF) gekennzeichnet. Nachdem der KF diese Anfrage empfangen hat, prüft er die erste Bedingung für das Aufschließen: nämlich ob die maximale Anzahl von Fahrzeugen in der Kolonne bereits erreicht wurde (Schritt 2). Ist dies nicht der Fall, wird die aktuelle Geschwindigkeit $v_{\mathrm{AF,akt}}$ und Position $s_{\mathrm{AF,akt}}$ des AFs überprüft (Schritt 3). Liegen diese innerhalb vordefinierter Bereiche, wird der KF das Aufschließ-Manöver genehmigen und das AF wird nun in FF (FF2 in Abbildung 6.8) umbenannt (Schritt 4). Sobald der erforderliche Abstand zwischen dem

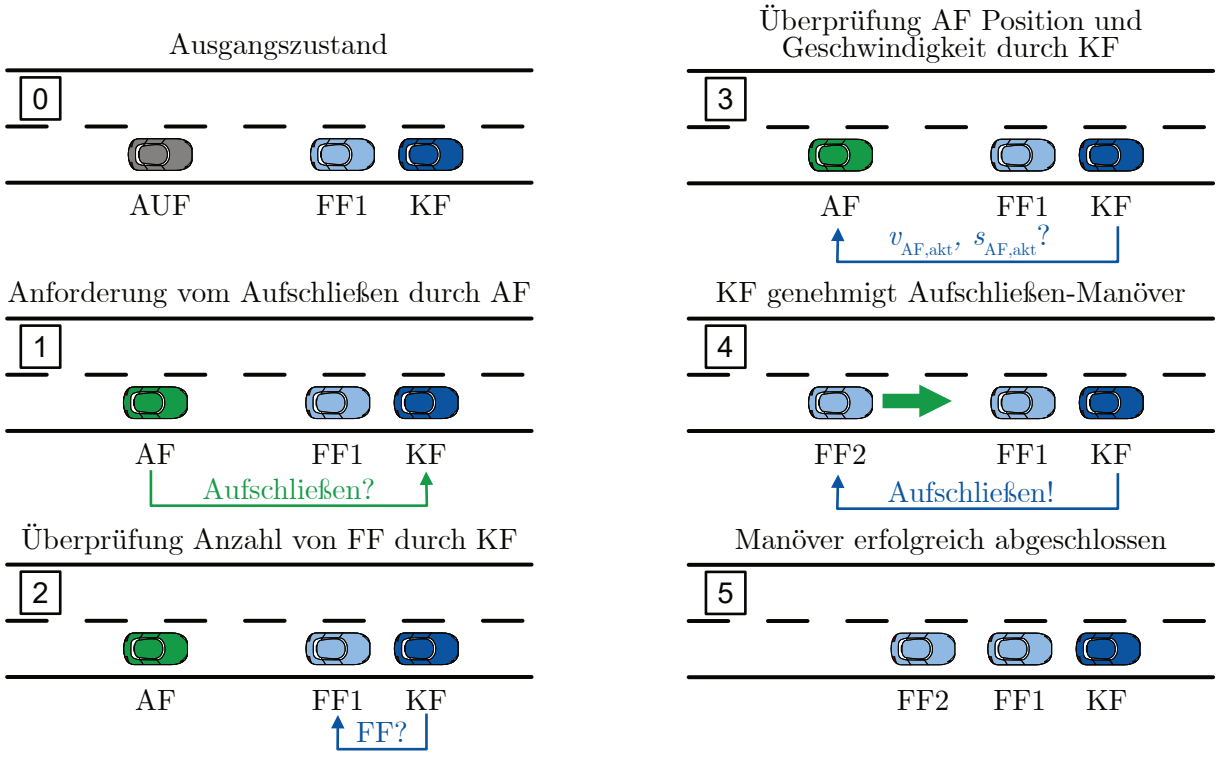

Abbildung 6.8: Schematische Darstellung eines Aufschließ-Manövers von einem AUF inklusive des Signalaustauschs

aufschließenden und dem vorausfahrenden Fahrzeug in der Kolonne erreicht wird, ist das Manöver erfolgreich abgeschlossen (Schritt 5).

Aufgrund der Änderung der Zustandsvariablen im Optimierungsproblem müssen die Nebenbedingungen und die Gewichtungsfaktoren der MPR modifiziert werden, um große Schwankungen in den Stellgrößen zu vermeiden:

- Die maximale Abstandslimitierung zwischen dem aufschließenden und dessen vorausfahrenden Fahrzeugs $d_{\mathrm{AF}}(k)$ wird erhöht:

$$d_{\mathrm{AF}}(k) \leq d_{\max} + t_{\mathrm{d,AF,max}} \cdot v_{\mathrm{AF}}(k), \text{ mit } t_{\mathrm{d,AF,max}} > t_{\mathrm{d,max}}. \tag{6.15}$$

- Die Gewichtungsfaktoren $\boldsymbol{Q}_{\mathbf{AF}}$ und $\boldsymbol{R}_{\mathbf{AF}}$ des aufschließenden Fahrzeugs werden während des Aufschließens auf 20 % des Wertes von KF und FF verringert:

$$\boldsymbol{Q}_{\mathbf{AF}} = 20\,\% \cdot \boldsymbol{Q}_{\mathbf{KF/FF}}, \ \boldsymbol{R}_{\mathbf{AF}} = 20\,\% \cdot \boldsymbol{R}_{\mathbf{KF/FF}}. \tag{6.16}$$

Die Erweiterung der maximalen Abstandslimitierung ermöglicht es dem AF mit einem größeren Abstand der Kolonne beizutreten. Die Reduzierung der Gewichtung resultiert in einem kleineren Anteil der Kostenfunktion, somit darf das AF mit einer höheren Beschleunigung der Kolonne aufschließen während der KF und die FF nicht verzögern müssen.

Um die Fahrmanöver graphisch abzubilden, werden in Abbildung 6.9 die Position, die zurückgelegten Strecken sowie die Beschleunigungen, Geschwindigkeiten, Abstände und die Anforderung von Aufschließen aller Fahrzeuge in Kolonne 3 während eines aufschließenden Manövers dargestellt.

Ab 590 s folgt der KF_3 dem VF_3 und eine Anforderung zum Aufschließen wurde jeweils von FF1

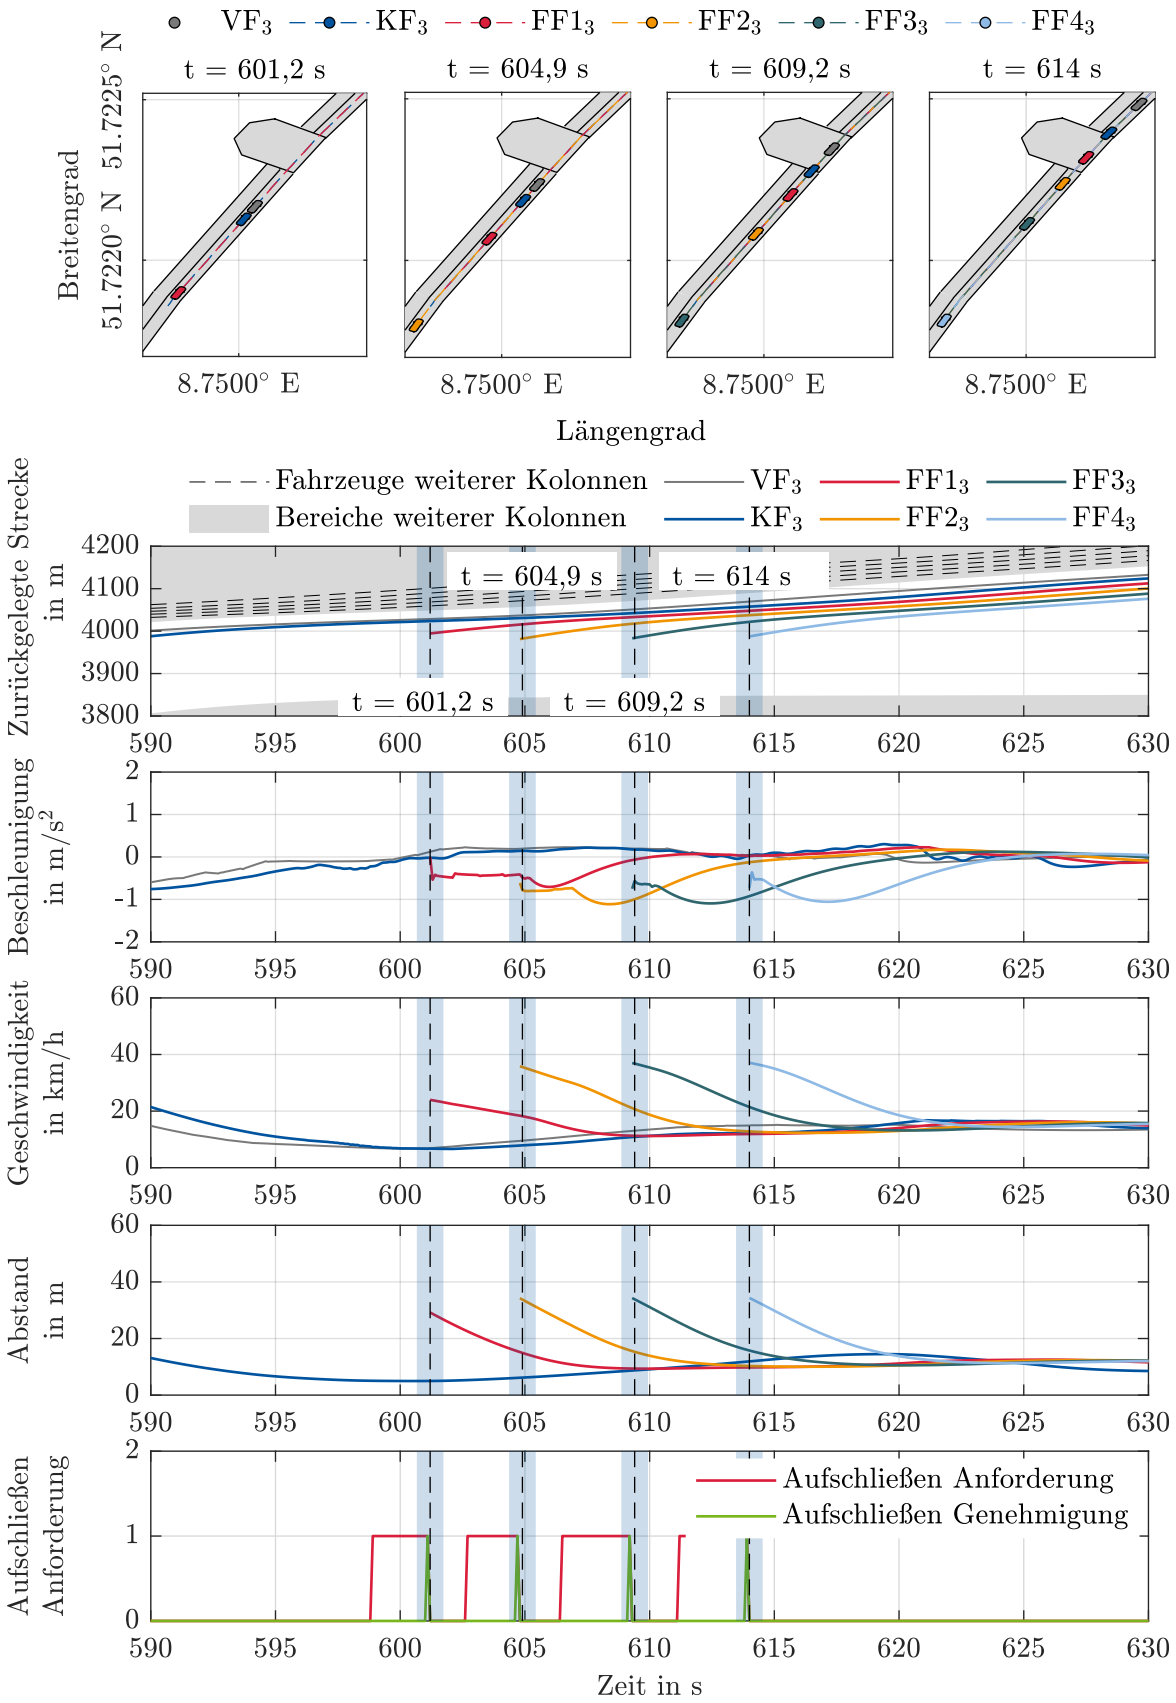

Abbildung 6.9: Auswertung der Simulationsergebnisse zwischen 590 s und 630 s für ein exemplarisches Aufschließ-Manöver von vier FF

bis FF4 an KF geschickt. Die Bedingungen zum Beitreten, der Abstand und die Geschwindigkeit von FF, sind nicht direkt erfüllt, sodass der KF das Aufschließen nicht unmittelbar nach der An-

forderung genehmigt hat. Die FF1 bis FF4 senden weiter die Anforderung an das KF und sobald die Bedingungen bei 601,2 s, 604,9 s, 609,2 s,und 614 s erfüllt sind, wird der KF ein Signal zur Genehmigung des Aufschließens zurück an das jeweilige FF schicken und nimmt gleichzeitig das FF in die Kolonne auf. Gemäß der Abbildung 6.9 lässt sich beobachten, dass zum Zeitpunkt des Beitretens die Abstände der FF etwa 35 m betragen und die Geschwindigkeiten im Bereich von 20 bis 40 km/h liegen. Aufgrund einer geringeren Geschwindigkeit des KFs von etwa 15 km/h verlangsamen sich die FF mit einer negativen Beschleunigung von -1 m/s^2 und somit reduzieren sich die Abstände auf ca. 11 m. Nach erfolgreicher Aufnahme aller FF in die Kolonne, folgen diese dem KF mit einer Geschwindigkeit von 15 km/h und halten dabei den Abstand von ca. 11 m zueinander bei.

6.3.2 Einscheren

Analog zum Aufschließ-Manöver ermöglicht das Einscher-Manöver ebenfalls den Zugang eines Fahrzeugs zur Kolonne. Dieser folgt allerdings seitlich über einen Fahrstreifenwechselvorgang. Folgende Grundvoraussetzungen gelten während des Einscher-Manövers:

- Das einscherende Fahrzeug verfügt über die Fähigkeit zur V2V-Kommunikation.
- Das einscherende Fahrzeug befindet sich in dem angrenzenden Fahrstreifen zur Kolonne und seine Fahrtrichtungsanzeige ist aktiviert.
- Die maximale Anzahl an Fahrzeugen in der Kolonne wurde bislang noch nicht erreicht.

In Abbildung 6.10 ist ein Beispiel gezeigt, an welchem der Ablauf eines solchen Szenarios erläutert wird. Bestrebt ein AUF, seitlich in die Kolonne einzutreten, signalisiert es dies durch Setzen des entsprechenden Fahrtrichtungsanzeigers (Schritt 0). In jedem Zeitschritt prüfen alle Kolonnenfahrzeuge, ob umliegend ein einscherendes Fahrzeug (EF) existiert (Schritt 1). In der Abbildung wird dies über den hellgrauen Suchbereich dargestellt, in diesem der KF nach einem EF sucht. Im gezeigten Fall existiert ein EF und nun wird eine Anfrage für das Einscheren von dem EF an den KF geschickt (Schritt 2). Nach der Überprüfung der Anzahl von FF sowie der Position $s_{\mathrm{EF,akt}}$ und Geschwindigkeit $v_{\mathrm{EF,akt}}$ vom EF durch KF (Schritt 3 und 4), wird die optimale Einscherposition durch KF bestimmt (Schritt 5). Dabei erfolgt im Hintergrund auf Basis der Relativgeschwindigkeiten und Abstände eine Berechnung der situationsbedingten optimalen Position für das Einscheren des EFs. Basierend auf dieser Position wird ein größerer Relativabstand zwischen den Kolonnenfahrzeugen für das EF eingerichtet, der durch Anpassung der Referenztrajektorien der betroffenen Teilnehmer erreicht wird (Schritt 6). Sobald der notwendige Abstand erreicht ist, gibt der KF das Einscher-Manöver frei (Schritt 7). Nachdem das EF in den Fahrstreifen der Kolonne eingegliedert ist, wird es in die Zentralregelung integriert und das Einscher-Manöver ist erfolgreich abgeschlossen (Schritt 8). Um energieeffizientes Einscheren zu ermöglichen, ist die Bestimmung der Einscherposition ein zentraler Bestandteil des Manövermanagements. Basierend auf dem im Kapitel 6.2 beschriebenen Folgefahr-Szenario kann das Optimierungsproblem erweitert werden. Die Situation für die Berechnung mit der möglichen Einscherposition 3 wird in Abbildung 6.11 dargestellt.
Nachdem ein EF eine Anfrage für das Einscheren an den KF gesendet hat, werden zunächst die verfügbaren Einscherpositionen festgestellt. Z. B. wenn die Kolonne aktuell aus vier Fahrzeuge be-

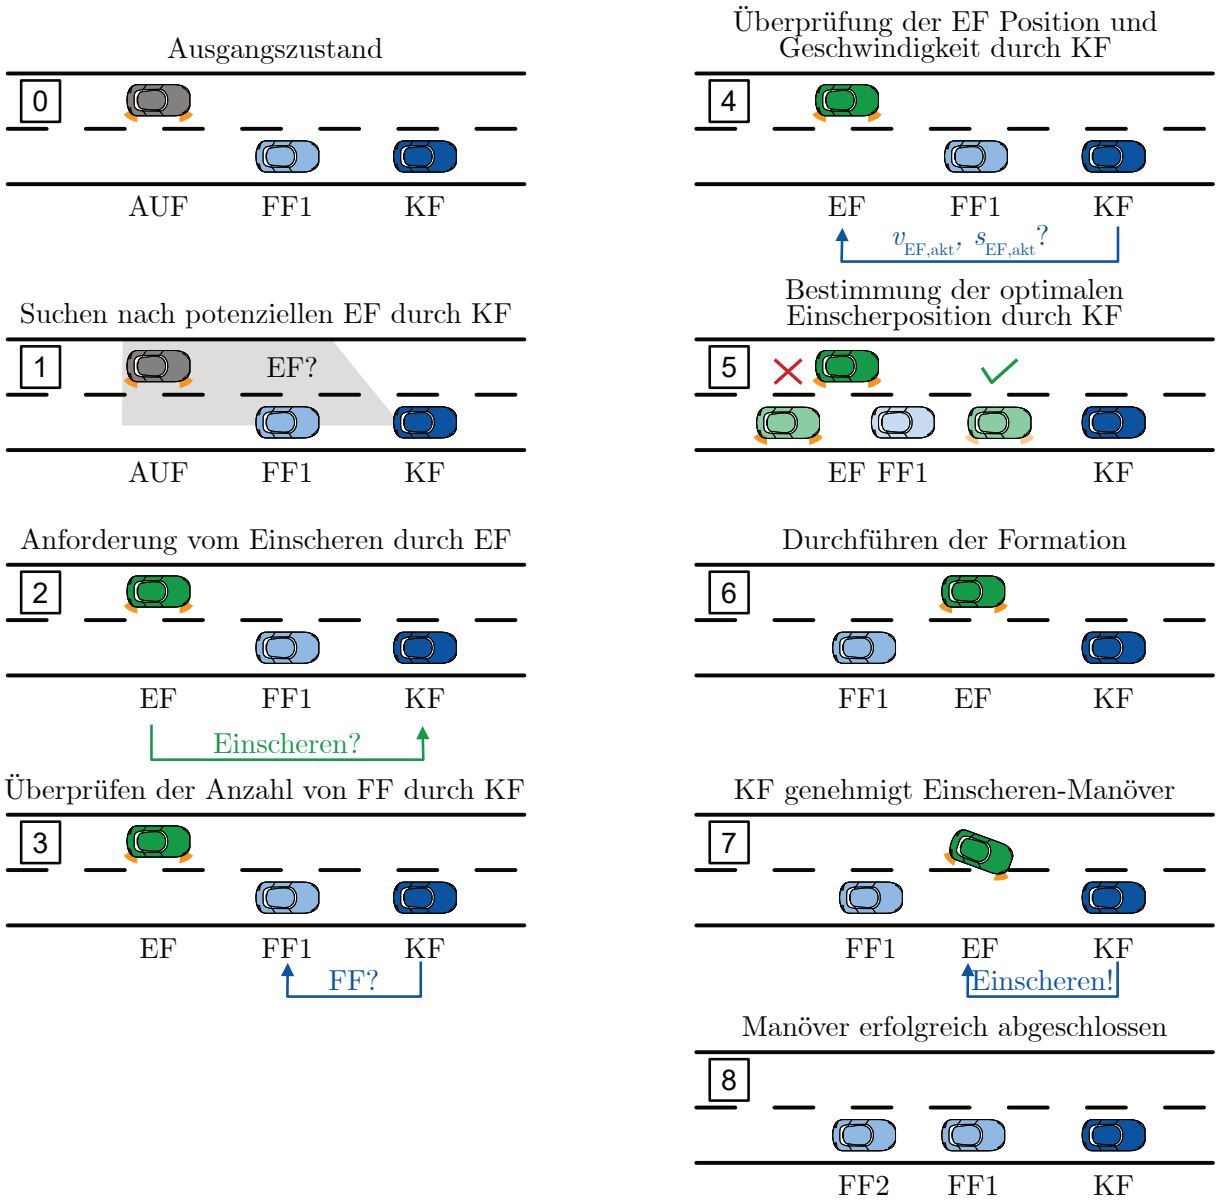

Abbildung 6.10: Schematische Darstellung eines Einscher-Manövers von einem AUF inklusive des Signalaustauschs

steht, ergeben sich insgesamt vier mögliche Einscherpositionen $n_{\text{einscheren}} = 1...4$. Das EF wird in das Optimierungsproblem aufgenommen und zuerst als letztes Fahrzeug, beispielsweise als fünftes Fahrzeug $n_{\text{Fzg}} = 5$, berücksichtigt.

Die Kostenberechnung für alle potenziellen Einscherpositionen $n_{\text{einscheren}} = 1...n$ erfolgt anhand der Gl. 6.13. Dabei werden die Nebenbedingungen wie folgt modifiziert:

$$\begin{aligned} d_{\text{FF},\text{n}_{\text{einscheren}}}(k) &\leq 2 \cdot (d_{\max} + t_{\text{d,max}} \cdot v_{\text{FF}}(k)) \\ d_{\text{FF},\text{n}_{\text{einscheren}},\text{ref}}(k) &= 2 \cdot (d_{\text{ref}} + t_{\text{d,ref}} \cdot v_{\text{FF}}(k)) \end{aligned} \tag{6.17}$$

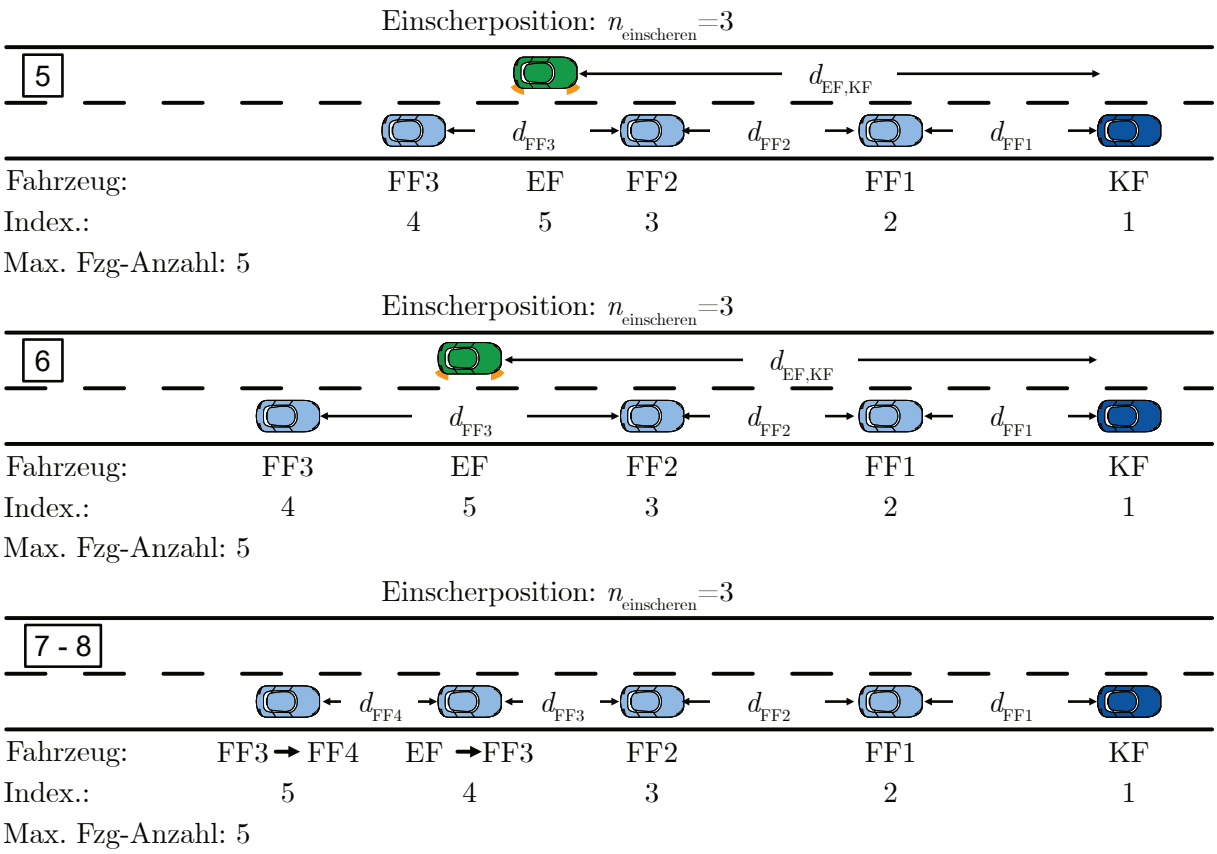

Abbildung 6.11: Schematische Darstellung der Berechnung der energieoptimierten Einscherposition eines EFs in einer Kolonne mit vier Fahrzeugen

wobei $d_{\mathrm{FF,n_{einscheren}}}(k)$ den Abstand zwischen dem Fahrzeug hinter der Einscherposition $n_{\mathrm{einscheren}} = 1...n$ und dessen vorausfahrenden Fahrzeugs beschreibt, wie in Abbildung 6.11 durch $d_{\mathrm{FF1...FF3}}$ veranschaulicht. Um den erforderlichen Abstand für das EF zu gewährleisten, werden sowohl das obere Limit als auch der Referenzabstand für das FF $d_{\mathrm{FF,n_{einscheren},ref}}(k)$ verdoppelt. Die untere Abstandslimitierung bleibt unverändert, um sicherzustellen, dass die aktuellen Systemzustände innerhalb der Grenzen liegen und das Optimierungsproblem lösbar bleibt. Für das EF gelten folgende Änderungen:

$$\begin{aligned} d_{\mathrm{EF,KF}}(k) &\leq d_{\mathrm{EF,max}} \\ d_{\mathrm{EF,KF}}(k) &\geq d_{\mathrm{EF,min}} \\ d_{\mathrm{EF,KF,ref}}(k) &= d_{\mathrm{ref}} + t_{\mathrm{d,ref}} \cdot v_{\mathrm{EF}} + \sum_{n=1}^{n_{\mathrm{einscheren}}-1} d_{\mathrm{FF,n}}(k) \end{aligned} \tag{6.18}$$

Der Abstand des EFs zum KF $d_{\mathrm{EF,KF}}(k)$ wird in Abhängigkeit der Kolonnenlänge durch konstante obere und untere Grenzwerte $d_{\mathrm{EF,max/min}}$ limitiert, während der Referenzabstand $d_{\mathrm{EF,KF,ref}}(k)$ zusätzlich den Anteil der Abstände von vorausfahrenden Fahrzeugen beinhaltet. Um das Einscher-Manöver, falls erforderlich, effizient durchzuführen und den Verkehr nicht zu behindern, muss der Abstand für das EF zügig vergrößert werden. Hierfür wird die Gewichtungsmatrix $\boldsymbol{Q}$ in Gl. 6.9 für das EF und Kolonnenfahrzeug mit der Indexnummer, die um eins größer ist als die Einscherposition $\mathrm{FF}_{n_{\mathrm{einscheren}}+1}$, wie folgt angepasst:

$$
\begin{aligned}
Q_{\mathrm{d,EF}} &= Q_{\mathrm{d,FF,n_{einscheren}+1}} = Q_{\mathrm{d,FF}} \\
Q_{\mathrm{v,EF}} &= Q_{\mathrm{v,FF,n_{einscheren}+1}} = 10\,\% \cdot Q_{\mathrm{v,FF}} \\
Q_{\mathrm{besch/verz,EF}} &= Q_{\mathrm{besch/verz,FF,n_{einscheren}+1}} = 15\,\% \cdot Q_{\mathrm{besch/verz,FF}}
\end{aligned}
\tag{6.19}
$$

Somit bleiben die Gewichtungen für die Abstände, $Q_{\mathrm{d,EF}}$ und $Q_{\mathrm{d,FF,n_{einscheren}+1}}$, unverändert, während die Gewichtungen für die Geschwindigkeiten, $Q_{\mathrm{v,EF}}$ und $Q_{\mathrm{v,FF,n_{einscheren}+1}}$, sowie für Beschleunigung und Verzögerung, $Q_{\mathrm{besch/verz,EF}}$ und $Q_{\mathrm{besch/verz,FF,n_{einscheren}+1}}$, reduziert werden. Dadurch kann das betroffene Kolonnenfahrzeug hinter der Einscherposition $\mathrm{FF}_{n_{\mathrm{einscheren}}+1}$ zügig verzögern, um den Abstand zu vergrößern und das EF erreicht dementsprechend den Abstand zum Kolonnenfahrzeug, hinter dem es sich einsortieren möchte.

Für jede mögliche Einscherposition wird das Optimierungsproblem anhand Gl. 6.13 gelöst, um die Kosten zu berechnen. Anschließend wird die Einscherposition mit den geringsten Kosten ausgewählt, für dieses Manöver festgehalten und an die zentralisierte Kolonnenregelung für die Folgefahrt (Kapitel 6.2) weitergeleitet. Sobald die Abstände des FF3s d_{FF3} und von EF zum KF $d_{\mathrm{EF,KF}}$ die Voraussetzungen zum Einscheren erfüllen, sendet der KF ein Signal an das EF für die Genehmigung des Manövers. Das EF wechselt den Fahrstreifen und gleichzeitig wird die Anordnung in der MPR umsortiert. Das EF wird in die Position mit der Indexnummer $n_{\mathrm{einscheren}} + 1$ einsortiert und die Indexnummern aller Fahrzeuge hinter dieser Position jeweils um eins erhöht.

Die Ergebnisse in Abbildung 6.12 repräsentieren ein Einscher-Manöver und zeigen die Position, die zurückgelegte Strecken, Beschleunigungen, Geschwindigkeiten, Abstände aller Fahrzeuge in einer Kolonne sowie die Einscherposition und -anforderung.

Bei 1173,6 s sendet das EF eine Anforderung zum Einscheren an den KF, woraufhin die Einscherposition vom KF berechnet wird. Zu Beginn wird eine Einscherposition von 1 identifiziert, damit sich das EF zwischen KF und FF1 einsortiert. Die Zustände aller Kolonnenfahrzeuge und des EFs werden nun durch die zentralisierte Kolonnenregelung geregelt. Der Abstand zwischen KF und FF1 (rote Linie) sowie der zwischen EF und KF (schwarze gestrichelte Linie) wird vergrößert. Sobald beide Abstände bei 1176,2 s die Einscherbedingung erfüllen (hierbei beträgt der Abstand zwischen KF und FF ca. 11 m und zwischen KF und EF 1 m), sendet der KF ein Signal zur Genehmigung des Einscher-Manövers an das EF zurück, welches daraufhin mit dem Fahrstreifenwechsel beginnt. Aufgrund der Abweichungen zwischen dem vorhergesagten und tatsächlichen Fahrzeugverhalten wird während des Fahrstreifenwechsels festgestellt, dass die Einscherposition von 1 auf 2 und wieder zurück auf 1 wechselt. Bei 1180 s hat sich das EF bereits auf den Fahrstreifen der Kolonne begeben und zum Zeitpunkt von 1181,1 s ist der Fahrstreifenwechsel abgeschlossen. Die Indexnummern der Kolonnenfahrzeuge werden nun neu sortiert. In der dargestellten Situation wechselt das EF zu FF1 mit der Indexnummer 2, und die vorherige FF1 und FF2 werden zu FF2 und FF3.

Da die Berechnung der Einscherposition auf einer Prädiktion basiert, kann diese bei einer unerwarteten Änderung der Verkehrssituation oder aufgrund von Prädiktionsfehlern angepasst werden. Dies kann dazu führen, dass die Einscherposition während des Manövers mehrfach variiert wird. Die Änderung der Einscherposition verursacht Schwankungen in dem Beschleunigungs- sowie Geschwindigkeitsverlauf und hat negative Einflüsse auf den gesamten Energiebedarf. Um diese Schwankung

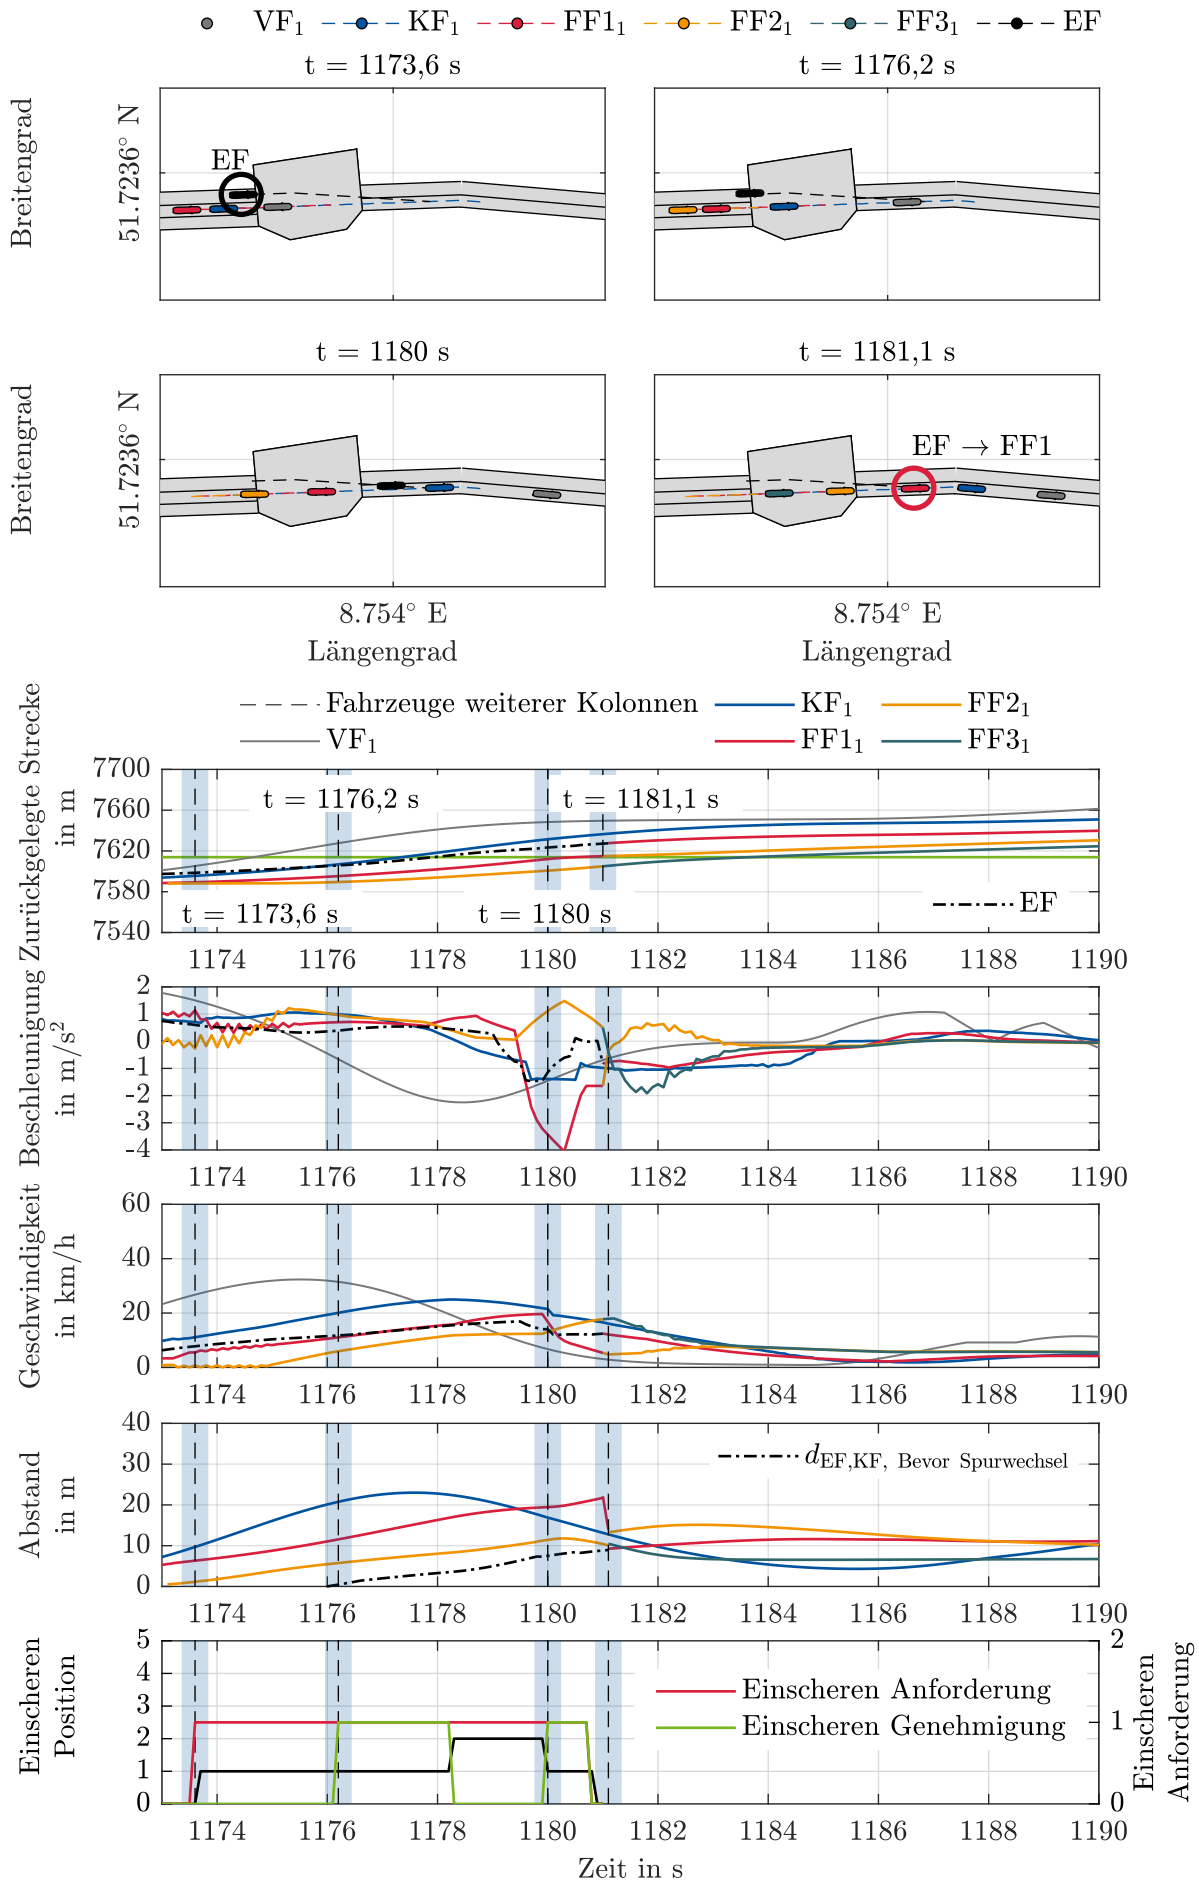

Abbildung 6.12: Auswertung der Simulationsergebnisse für ein exemplarisches Einscher-Manöver in einer Kolonne mit zwei FFs

zu minimieren, wird die berechnete Einscherposition für mindestens 0,5 s beibehalten, bevor eine Änderung vorgenommen werden darf.
Das kooperative Einscher-Manöver ermöglicht es der Kolonne ein weiteres AUF von einer benachbarten Fahrbahn aufzunehmen und verhindert gleichzeitig eine Blockierung der eigenen Fahrbahn aufgrund der geringen Abstände zwischen den Kolonnenfahrzeugen. Insbesondere können Einscher-Manöver auf Straßen beobachtet werden, die von zweispurig auf einspurig übergehen.

6.3.3 Ausscheren

Ein Ausscher-Manöver tritt auf, wenn ein Kolonnenfahrzeug den aktuellen Fahrstreifen wechselt, beispielsweise aufgrund eines bevorstehenden Abbiegemanövers oder einer Änderung der Route. In der zentralisierten Kolonnenregelung kann ein solches Manöver durchgeführt werden. Eine schematische Darstellung der Regelung des Ausscherens ist in Abbildung 6.13 dargestellt.

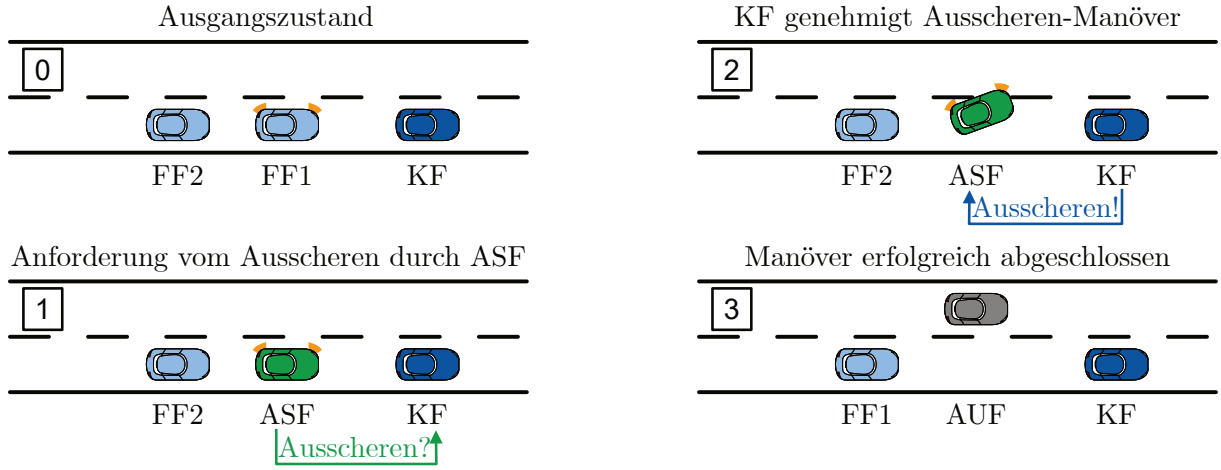

Abbildung 6.13: Schematische Darstellung eines Ausscher-Manövers von einem ausscherenden Fahrzeug inklusive des Signalaustauschs

Das Fahrzeug, das sich zunächst in der Kolonne befindet, FF1, signalisiert seine Absicht, die Kolonne zu verlassen, indem es den Fahrtrichtungsanzeiger aktiviert (Schritt 0). Nachdem das ausscherende Fahrzeug (ASF) eine Anforderung zum Ausscheren an KF gesendet hat, nimmt der KF diese Anforderung auf (Schritt 1) und gibt das Manöver frei (Schritt 2). Das ASF überprüft eigenständig die Bedingungen für ein gefahrloses Ausscheren, insbesondere, ob sich keine weiteren Fahrzeuge neben der Kolonne befinden. Sind die Bedingungen erfüllt, beginnt das ASF die Kolonne zu verlassen. Während das ASF die Kolonne verlässt und sich noch zwischen zwei Fahrzeugen befindet, gibt der KF weiterhin die Beschleunigungswerte vor. Sobald das Fahrzeug den Zielfahrstreifen erreicht hat, wird dieses aus der Kolonne und der zentralisierten Kolonnenregelung entfernt, dadurch ist das Ausscher-Manöver erfolgreich abgeschlossen (Schritt 3).
Das Ausscher-Manöver tritt während der Simulationen häufig auf, Abbildung 6.14 veranschaulicht eines der Ausscher-Manövern graphisch. In einer Kolonne sendet das Fahrzeug FF1 eine Anforderung zum Ausscheren an den KF, wobei FF1 als ein ASF identifiziert wird. Diese Anforderung wird unmittelbar vom KF genehmigt und die Bedingungen für den Fahrstreifenwechsel von FF1 werden direkt erfüllt. Nach erfolgreichem Abschluss des Fahrstreifenwechsels um 538,8 s ist FF1 nicht länger

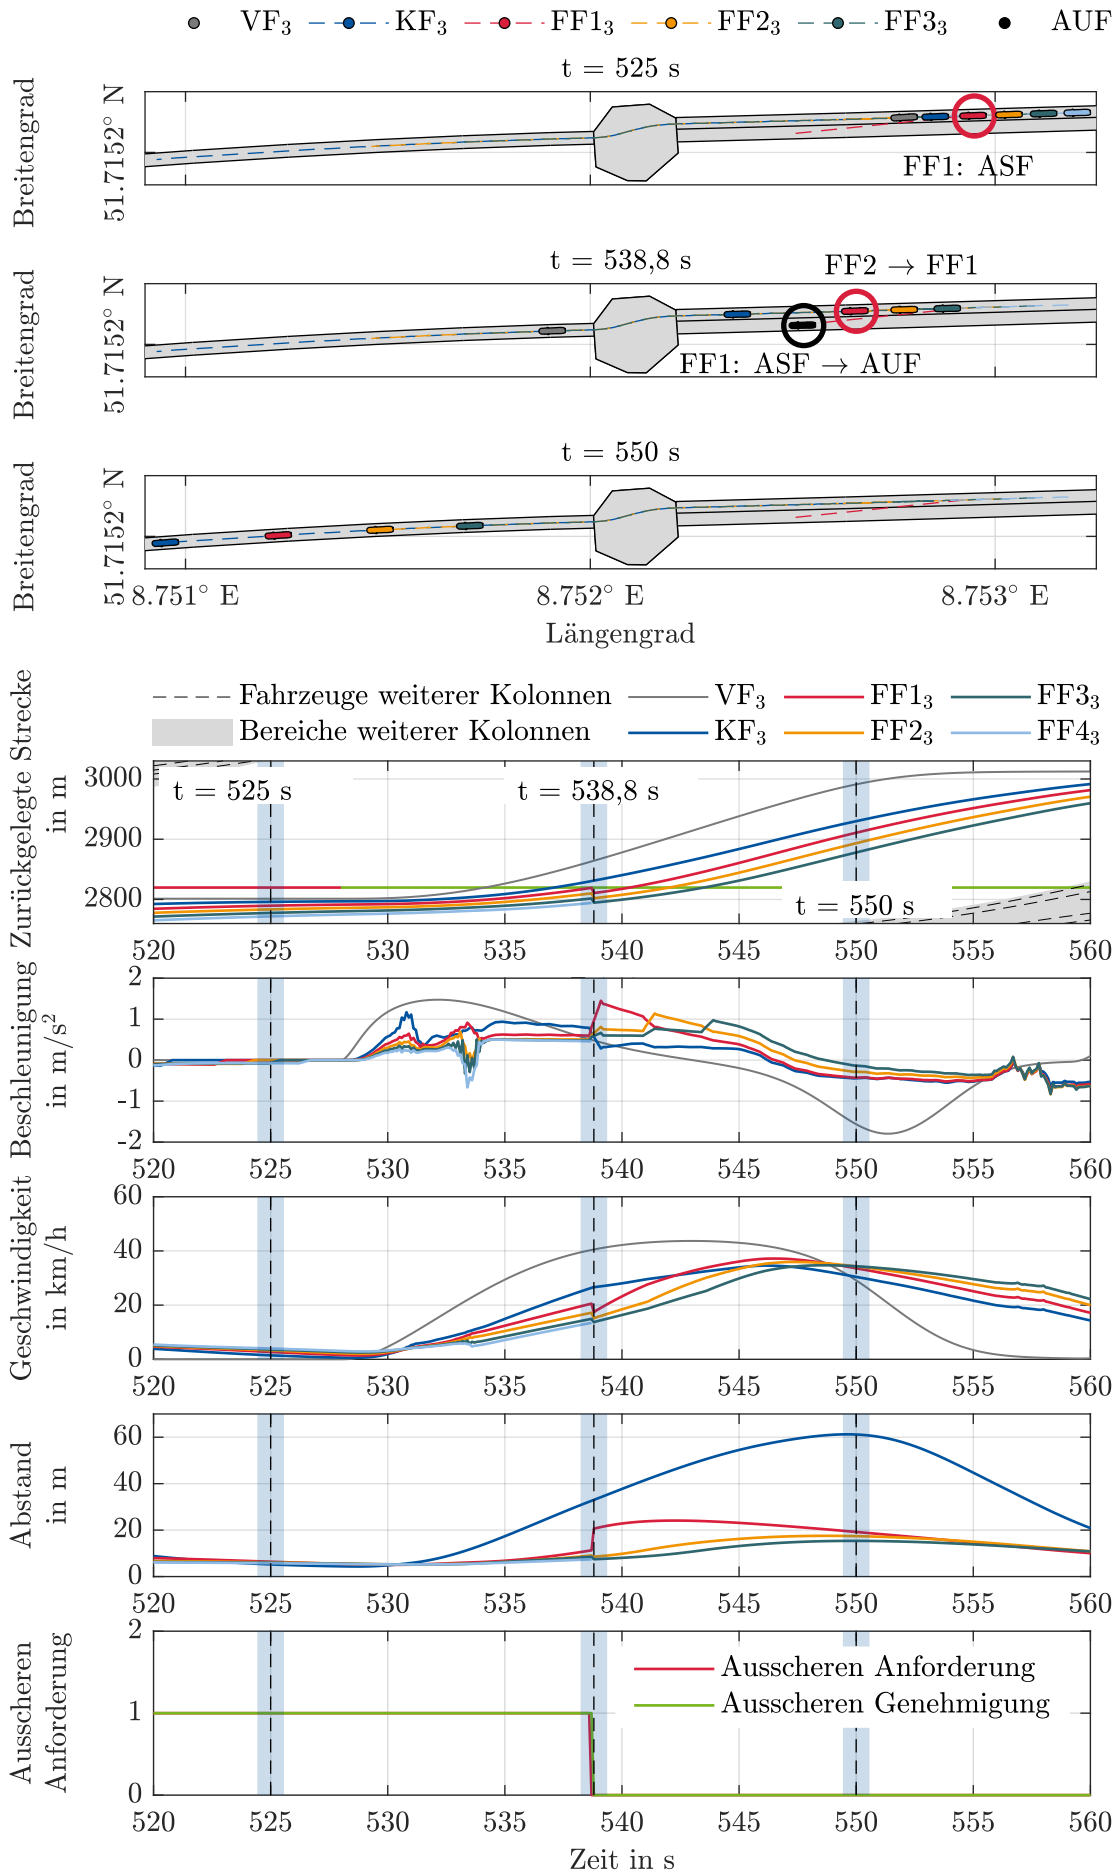

Abbildung 6.14: Auswertung der Simulationsergebnisse für ein beispielhaftes Ausscher-Manöver

Teil der Kolonne, und das zuvor als FF2 bezeichnete Fahrzeug übernimmt die Rolle von FF1 in der Kolonne. Bei 550 s ist der optimale Abstand zwischen dem KF und dem neuen FF1 erreicht.
Es ist nicht immer möglich, die Bedingungen für einen gefahrlosen Fahrstreifenwechsel sofort zu erfüllen. Aufgrund eines weiteren Fahrzeugs auf dem Zielfahrstreifen kann dieser blockiert und das Ausscher-Manöver nicht durchgeführt werden. Erst wenn der benachbarte Fahrstreifen wieder frei ist, wird der Fahrstreifenwechsel durchgeführt und das als ASF identifizierte Fahrzeug aus der zentralisierten Kolonnenregelung entfernt.
Durch Analyse der Simulationsergebnisse lässt sich feststellen, dass nach einem Ausscher-Manöver vorübergehende Schwankungen in der Beschleunigung der Kolonnenfahrzeuge auftreten (z. B. bei 539 s). Dies ist auf die Neuanordnung der Indexnummern der Fahrzeuge im Optimierungsproblem zurückzuführen. Wenn beispielsweise die Indexnummer von 3 auf 2 wechselt, unterscheiden sich die aktuellen Zustände von denen, die durch die vorherige Lösung des Optimierungsproblems prädiziert wurden. Falls die vor dem Ausscher-Manöver prädizierten Abstände zwischen FF1 und KF durch einen größeren Abstand ersetzt werden, beschleunigt das neue FF1 nach dem Ausscher-Manöver, um sich dem Referenzabstand anzunähern.

6.3.4 Aufteilung

Ein weiteres bedeutendes Manöver im Zusammenhang mit urbanen Fahrszenarien ist die Aufteilung, die insbesondere in zwei spezifischen Situationen erforderlich ist: der Durchfahrt an einer LSA-gesteuerten Kreuzung und dem Fahrstreifenwechsel eines nicht-automatisierten Fahrzeugs (NAF).

Aufteilung durch LSA

Aufgrund der individuellen Schaltprogramme der LSA kann es dazu kommen, dass nicht alle Fahrzeuge einer Kolonne die Kreuzung während derselben grünen Phase passieren können. Aus diesem Grund ist eine Aufteilung der Kolonne notwendig. Eine schematische Darstellung der beschriebenen Aufteilung ist in Abbildung 6.15 zu sehen.
Sobald eine signalisierte Kreuzung in der Reichweite einer Fahrzeugkolonne liegt (Schritt 0), erfasst der KF die Position und das Schaltprogramm der vorausliegenden LSA über die V2I-Kommunikation (Schritt 1). Anhand dieser Informationen berechnet der KF die optimale Aufteilungsposition für die Kolonne (Schritt 2). Falls alle Fahrzeuge die Kreuzung in derselben Grünphase passieren können, ist keine Aufteilung erforderlich. Andernfalls sendet der KF eine Anforderung zur Aufteilung an diejenigen Fahrzeuge, die nicht in der gleichen Grünphase die Kreuzung passieren können, und übergibt damit die Kontrolle an die Geschwindigkeitsregelung der Fahrzeuge. Somit werden diese Fahrzeuge von der Kolonne entfernt und wieder als AUF bezeichnet (Schritt 3 und 4). Die Fahrzeuge in der Kolonne passieren die Kreuzung, während die aufgeteilten Fahrzeuge an der Haltelinie vor der LSA warten, bis diese in die nächste Grünphase einfahren können (Schritt 5).
Um die Berechnung der Aufteilungsposition zu veranschaulichen, zeigt Abbildung 6.16 beispielhaft die Prädiktion der zurückzulegenden Strecke aller beteiligten Fahrzeuge (links) und die Aufteilung der Kolonne (rechts).

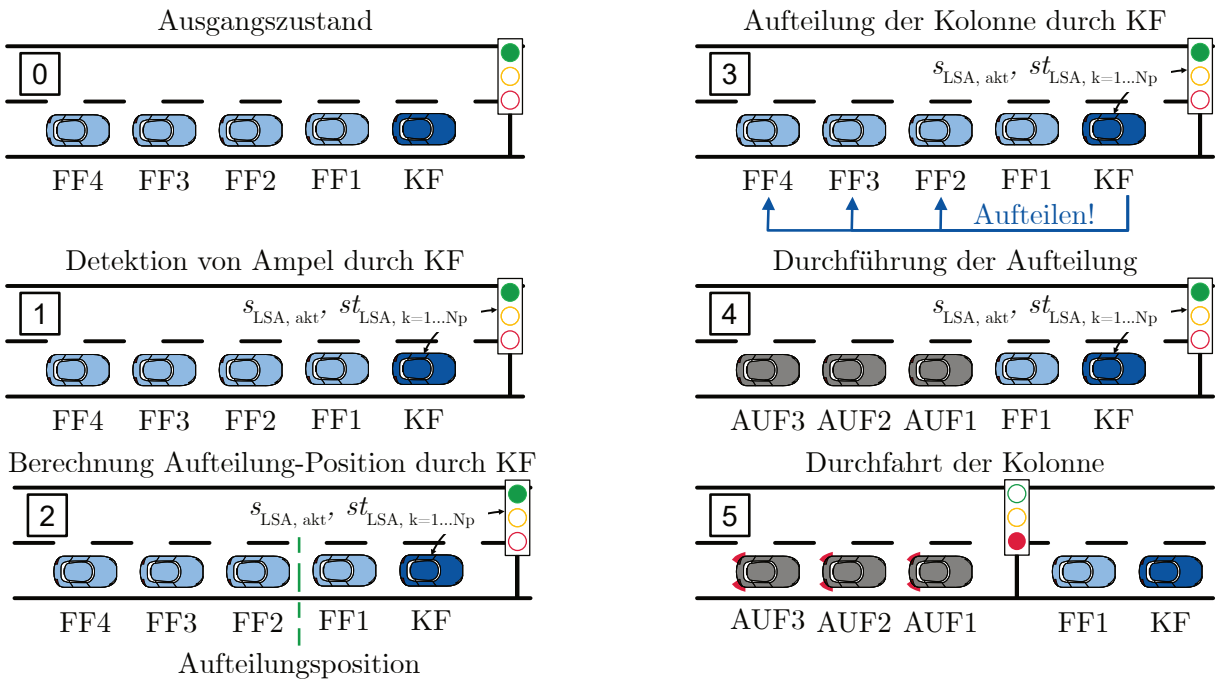

Abbildung 6.15: Schematische Darstellung eines Aufteilungsmanövers einer Kolonne bei einer signalisierten Kreuzung inklusive des Signalaustauschs

Wenn eine Kolonne einem VF folgt und sich einer signalisierten Kreuzung nähert, werden die zurückzulegenden Strecken $s_{\text{Präd}}$, die alle Kolonnenfahrzeuge innerhalb des Prädiktionshorizonts N_{p} mit optimaler Beschleunigung erreichen können, anhand des im Kapitel 6.2 erläuterten Optimierungsproblems prädiziert und in Abbildung 6.16 auf der linken Seite dargestellt. Die basierend auf der Fahrzeugstrecken-Koordinate berechnete Position der vorausliegenden LSA wird als s_{LSA} bezeichnet. Die Phasen sowie deren Dauern sind jeweils in Grün, Gelb und Rot dargestellt. Falls die zurückzulegende Strecke eines Kolonnenfahrzeugs am Ende der ersten grünen Phase $t_{\text{Grün,Ende,1}}$ größer ist als die Position der LSA (z. B. VF, KF und FF1 in Abbildung 6.16), können diese die Kreuzung in der ersten grünen Phase passieren. Andernfalls muss dies von der Kolonne getrennt geschehen (z. B. FF2 bis FF4 in Abbildung 6.16).

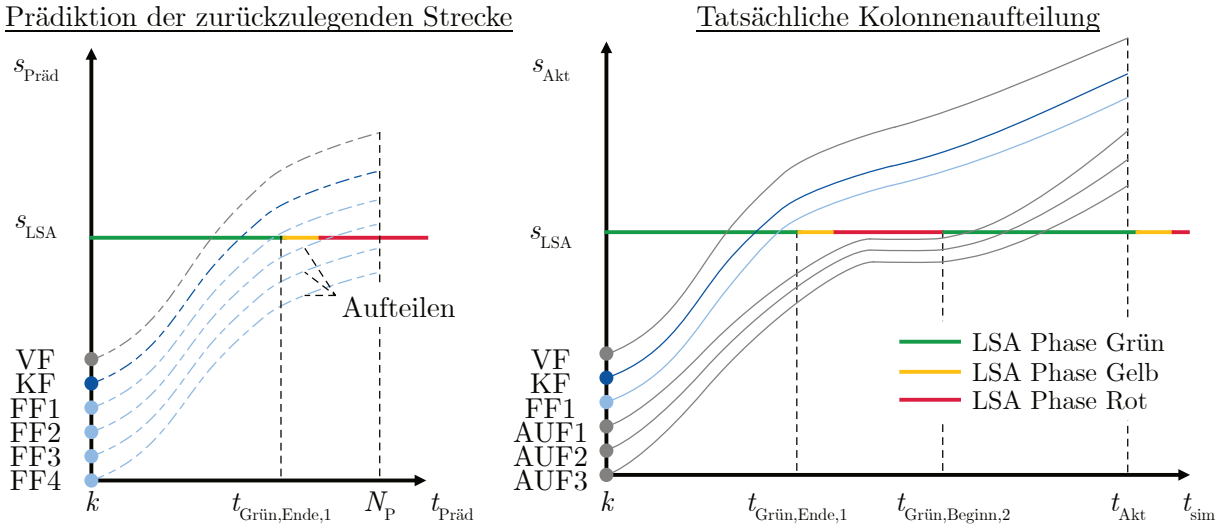

Abbildung 6.16: Schematische Darstellung der Berechnung der Aufteilungsposition: Positionsprädiktion (links) und tatsächliche Kolonnenaufteilung (rechts)

Auf der rechten Seite von Abbildung 6.16 werden die tatsächlich zurückgelegten Strecken s_{akt} aller Fahrzeuge ab dem Zeitpunkt k dargestellt. Sowohl KF als auch FF1 können dem VF folgen und die Kreuzung passieren, während FF2 bis FF4 jeweils AUF1 bis AUF3 werden und bei roter Phase an der LSA anhalten müssen. Beim Beginn der zweiten grünen Phase $t_{\text{Grün,Beginn,2}}$ werden diese Fahrzeuge anfahren und die Kreuzung in dieser zweiten grünen Phase passieren.
Dadurch dass die Berechnung der Aufteilungsposition auf der Prädiktion basiert, können unvorhergesehene Verkehrssituationen eintreten, bei denen das KF bereits die Kreuzung passiert hat, aber eines der Kolonnenfahrzeuge, das mit dem KF die Kreuzung passieren sollte, an einer LSA mit roter Phase zum Stillstand gezwungen wird. Falls diese Fahrsituation eintritt, wird dieses Fahrzeug ebenfalls aus der Kolonne entfernt. Aus diesem Grund überwachen alle FF die Phase der LSA, sobald der KF diese passiert hat.
In Abbildung 6.17 werden die Fahrzeugposition, zurückgelegten Strecken, Beschleunigungen, Geschwindigkeiten, Abstände und die Aufteilungsposition dargestellt.
In der vorliegenden Fahrsituation befindet sich die vom KF aus gesehen nächste LSA auf 12,15 km und die aktuelle Grünphase endet bei 2116 s. Basierend auf der Prädiktion der zurückgelegten Strecke hat der KF bei 2103 s eine Aufteilungsposition von 3 ermittelt. Folglich ist es für die Fahrzeuge mit einer Indexnummer, die gleich oder größer als die Aufteilungsposition ist (FF2 und FF3), nicht möglich, die Kreuzung in derselben Grünphase wie der KF zu passieren und werden daher aus der Kolonne entfernt und zu AUF1 und AUF2. Gleichzeitig übernimmt das IDM-Fahrermodell die longitudinale Geschwindigkeitsregelung der aufgeteilten Fahrzeuge.
Unter Anwendung der zentralisierten Kolonnenregelung setzen KF und FF1 die Fahrt fort und haben bei 2125 s Strecken von 12,24 bzw. 12,23 km zurückgelegt, sodass diese bereits an der LSA vorbeigefahren und die Kreuzung passiert haben. Aufgrund der Entscheidung des IDM - Fahrermodells, können die AUF1 und AUF2 die Kreuzung nicht während der aktuellen Grünphase passieren. Dadurch müssen diese Fahrzeuge vor der LSA mit Rotphase zum Stillstand kommen und beim Beginn der nächsten Grünphase losfahren.
Nachdem die Geschwindigkeitsregelung der AUF1 und AUF2 bei 2103 s zurück an das IDM - Fahrermodell übergeben wird, können Verzögerungen mit jeweils -1.5 und -2.3 m/s^2 beobachtet werden, die Geschwindigkeiten von AUF1 und AUF2 reduzieren sich auf 45 km/h. Infolgedessen steigt der Abstand zwischen FF2 (AUF1) und FF1 von 34 m auf 55 m an. Der Grund hierfür ist, dass im IDM-Fahrermodell der Fahrzeugabstand über den Zeitabstand eingestellt wird, während die zentralisierte Kolonnenregelung darauf abzielt einen kleinen Referenzabstand unter optimalen Zuständen zu erreichen. Nach der Umschaltung der LSA von der Grün- zur Gelbphase verzögert das AUF1 mit -2.8 m/s^2 bis es vor der LSA zum Standstill kommt. Nach Ablauf der Rotphase beschleunigen sowohl das AUF1 als auch AUF2 beide mit ca. 2.6 m/s^2 und setzen die Fahrten fort.
Wie bereits erwähnt, können unvorhergesehene Verkehrssituationen wie z. B. ein Stau nach der Kreuzung mit der LSA dazu führen, dass die Geschwindigkeiten aller Fahrzeuge in der Kolonne verringert werden. Aufgrund dessen ist es möglich, dass einige Fahrzeuge die Kreuzung mit der aktuellen Grünphase nicht mehr passieren können. In Abbildung 6.18 wird eine derartige Fahrsituation graphisch dargestellt.

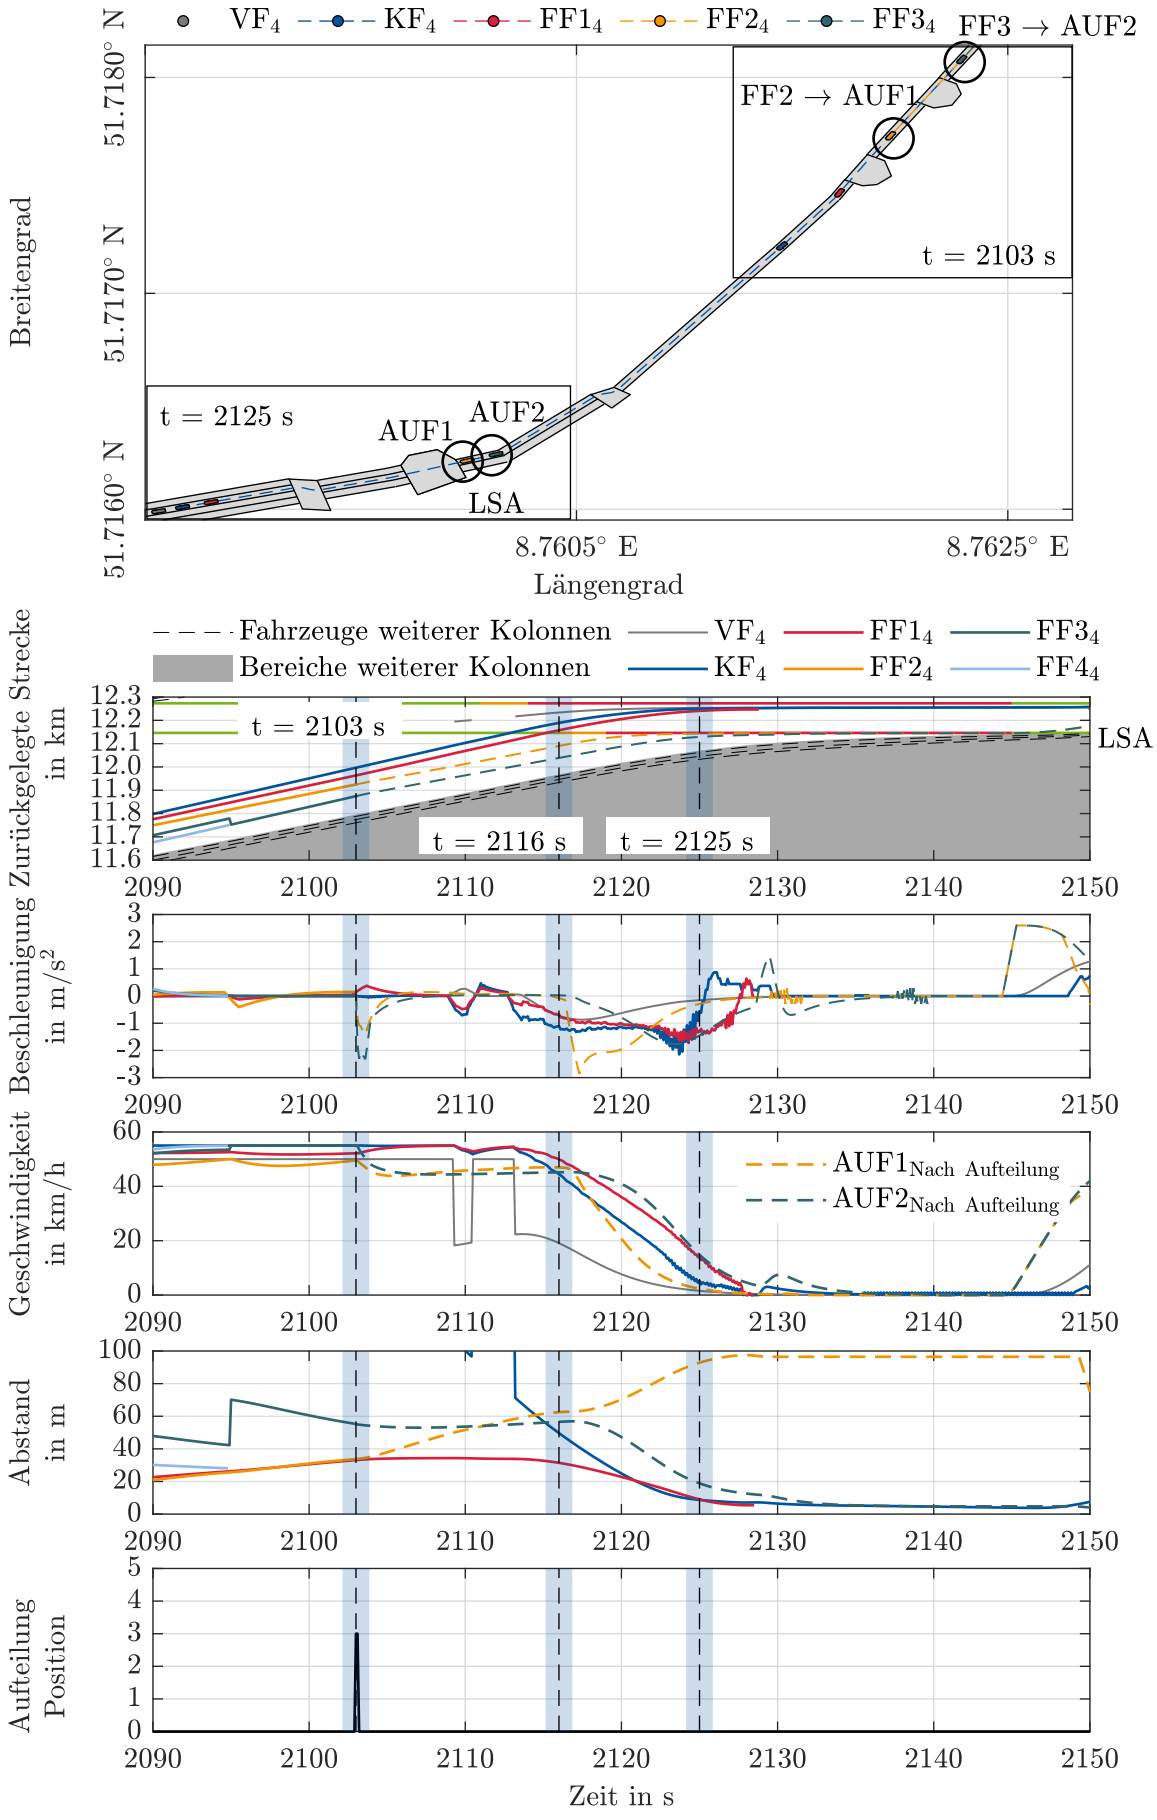

Abbildung 6.17: Auswertung der Simulationsergebnisse für ein beispielhaftes Aufteilungsmanöver durch eine LSA

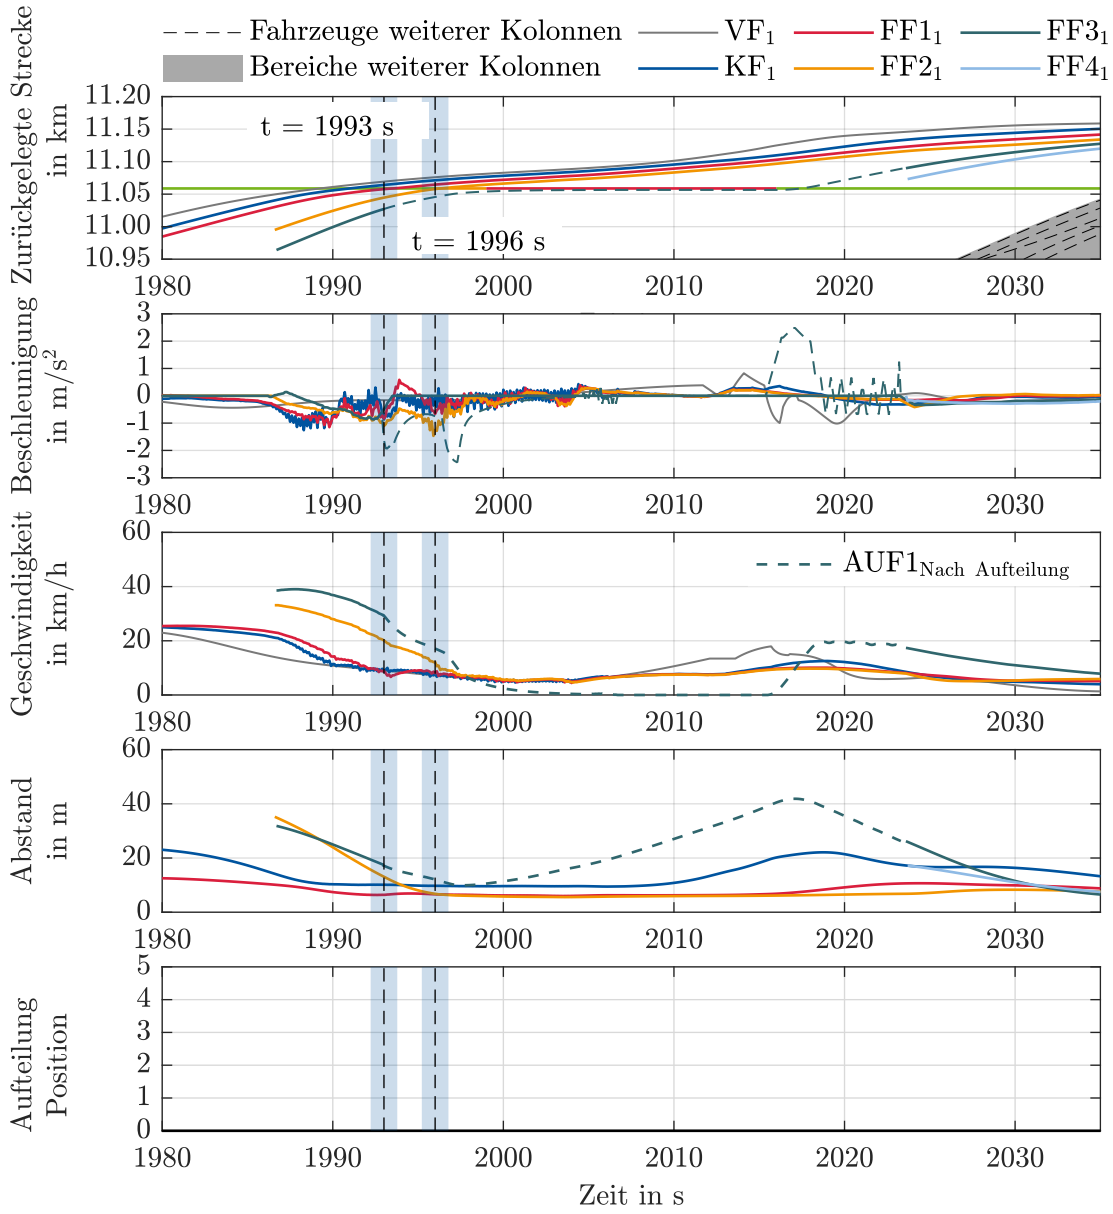

Abbildung 6.18: Auswertung der Simulationsergebnisse für ein beispielhaftes unvorhergesehenen Aufteilungsmanöver durch eine LSA

Die aktuelle Grünphase der LSA endet bei 1996 s und bevor der KF die LSA erreicht hat, ist eine Aufteilung der Kolonne auf Grundlage der Prädiktion der zurückzulegenden Strecke aller Kolonnenfahrzeuge nicht erforderlich. Folglich ist während dieses Zeitraums die in Abbildung 6.18 dargestellte Aufteilungsposition gleich null.

Allerdings verzögert das VF verkehrsbedingt nach dem Passieren der LSA auf ca. 6 km/h, was zu einer Reduktion der Geschwindigkeit der nachfolgenden Kolonnenfahrzeuge führt. Diese Situation wurde von dem KF nicht prädiziert. Infolgedessen ist das FF1 in der Lage, die Kreuzung zu überqueren, bevor die Gelbphase beginnt. Das FF2 hingegen kann die Kreuzung nicht während der Gelbphase passieren. Das FF2 erkennt diese Situation bei 1993 s und verlässt die Kolonne. Das fahrzeugeigene IDM-Fahrermodell übernimmt die Geschwindigkeitsregelung des AUF1 und verzögert mit ca. -2.5 m/s^2 bis das AUF1 vor der LSA zum Stillstand kommt. Nach der Rotphase setzt das AUF1 die Fahrt fort und schließt von hinten wieder zur Kolonne auf.

Derartige Situationen treten häufig am Ende eines Staus auf und die Fahrzeuge, die vor der LSA zum Stillstand erzwungen werden, weisen dabei vergleichsweise höhere Verzögerungen auf. Die Ursache liegt in der späten eigenen Erkennung des Wechsels der LSA-Phase durch das FF und dies kann zu einem erhöhten Energiebedarf führen.

Aufteilung durch nicht-automatisiertes Fahrzeug

Neben dem Aufteilungsmanöver durch eine LSA, können manuelle Fahrstreifenwechsel von einem NAF ebenfalls dazu führen, dass sich eine Kolonne aufteilt. In solchem Szenario ist ein umgebendes NAF von einem menschlichen Fahrermodell gesteuert und ist nicht in der Lage, Fahrzeuginformationen mit der Kolonne auszutauschen. Aufgrund des kleinen Fahrzeugabstands in einer Kolonne stellt der Fahrstreifenwechsel des NAFs eine Herausforderung dar, die bewältigt werden muss, um den Verkehrsfluss nicht zu behindern.

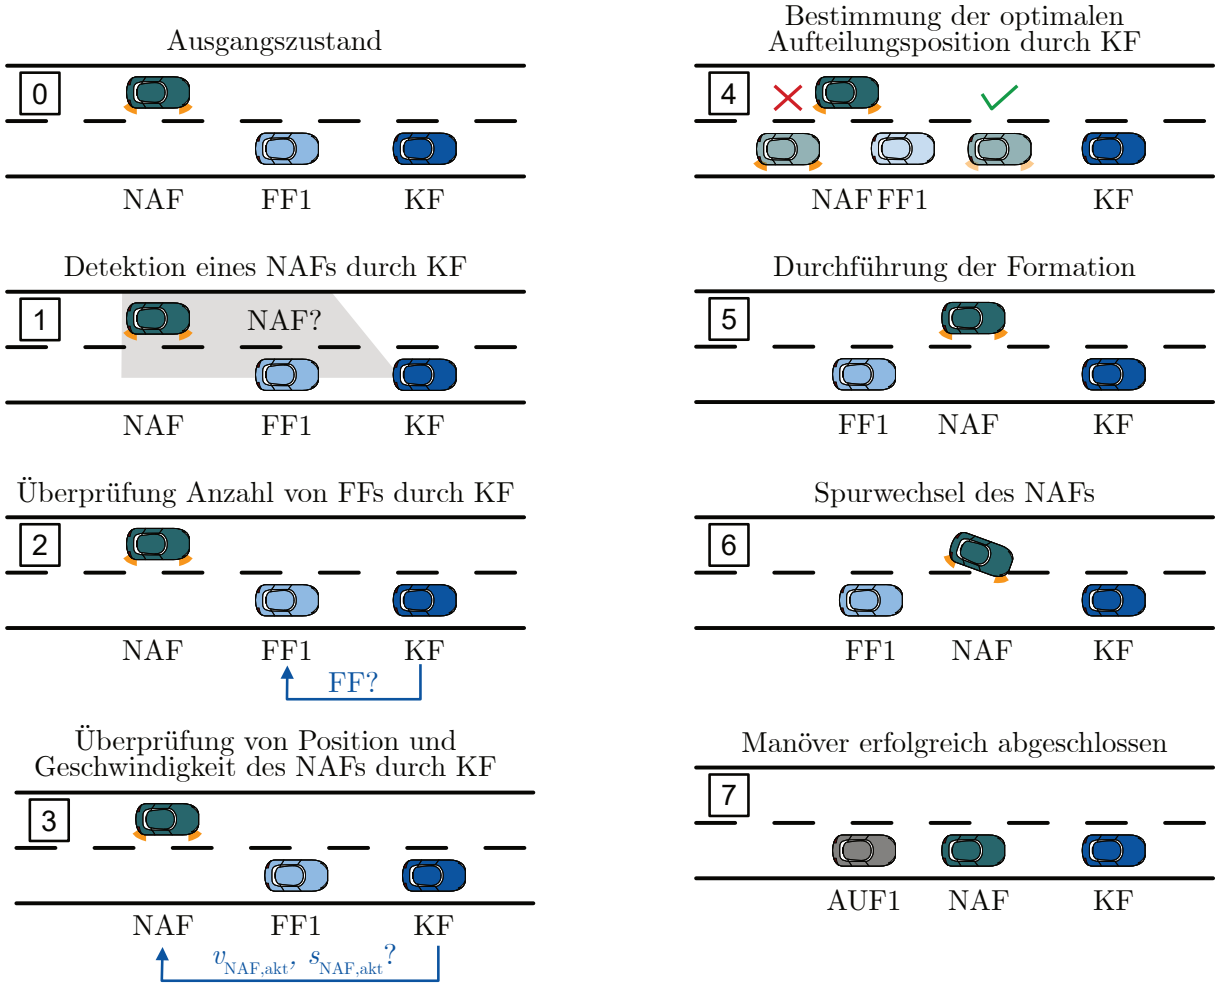

Abbildung 6.19: Schematische Darstellung des Aufteilungsmanövers einer Kolonne durch Fahrstreifenwechsel eines nicht-automatisierten Fahrzeugs

Um den Fahrstreifenwechsel eines NAFs zu ermöglichen und den Verkehrsfluss aufrechtzuerhalten, wird die Kolonne gemäß der in Abbildung 6.19 dargestellten Methode aufgeteilt.
Wenn sich ein NAF einer Kolonne nähert und durch die Aktivierung des Fahrtrichtungsanzeigers einen Fahrstreifenwechsel signalisiert (Schritt 0), werden die Kolonnenfahrzeuge zunächst das NAF

detektieren (Schritt 1). Sobald die Anforderung des Fahrstreifenwechsels erkannt wird, wird das KF die Anzahl der FF sowie die Position und Geschwindigkeit des NAFs überprüfen (Schritt 3 und 4). Vor jedem Fahrstreifenwechsel des NAFs ermittelt der KF in jedem Zeitschritt eine optimale Position zur Aufteilung und vergrößert den Abstand zwischen den betroffenen Kolonnenfahrzeugen (Schritt 5 und 6). Das NAF trifft eigenständig die Entscheidung hinsichtlich des Zeitpunkts und des Orts für den Fahrstreifenwechsel (Schritt 7). Nachdem das NAF den Fahrstreifen gewechselt hat, werden die nachfolgenden Fahrzeuge von der Kolonne getrennt und die Kontrolle wird an das IDM - Fahrermodell der Fahrzeuge übergeben. Auf diese Weise kann das Manöver erfolgreich abgeschlossen werden.

Ähnlich wie beim Einscheren, ist die Berechnung der Aufteilungsposition des NAFs Kern des Manövermanagements. Dazu wird die in Kapitel 5 erläuterte Trajektorienprädiktion eines NAFs verwendet. Das im Kapitel 6.2 beschriebene Optimierungsproblem wird ebenfalls erweitert und die Kosten für alle möglichen Aufteilungspositionen mithilfe der Gl. 6.13 berechnet.

Die Anpassung der Nebenbedingungen der FF erfolgt analog zur Gl. 6.17. Aufgrund dessen, dass das NAF nicht von der zentralisierten Kolonnenregelung gesteuert werden kann, wird die Geschwindigkeits- und Positionsprädiktion als Systemlimitierung betrachtet. Folgende Annahmen werden getroffen:

$$\begin{aligned} d_{\mathrm{NAF,min}} \leq d_{\mathrm{NAF,KF}}(k) \leq d_{\mathrm{NAF,max}} \\ d_{\mathrm{NAF,KF,ref}}(k) = s_{\mathrm{KF,Präd}}(k) - s_{\mathrm{NAF,Präd}}(k) \\ v_{\mathrm{NAF,ref}}(k) = v_{\mathrm{NAF,Präd}}(k) \\ v_{\mathrm{NAF}}(k) \leq v_{\mathrm{NAF,Präd}}(k) \end{aligned} \tag{6.20}$$

Die Limitierungen vom Abstand zwischen dem NAF zum KF $d_{\mathrm{NAF,KF}}(k)$ werden in Abhängigkeit der Kolonnenlänge festgelegt ($d_{\mathrm{NAF,max}}$ und $d_{\mathrm{NAF,min}}$), während der Referenzabstand $d_{\mathrm{NAF,KF,ref}}(k)$ der Differenz zwischen den prädizierten zurückgelegten Strecke des KFs $s_{\mathrm{KF,Präd}}(k)$ und des NAFs $s_{\mathrm{NAF,Präd}}(k)$ entspricht. Die prädizierte Geschwindigkeit $v_{\mathrm{NAF,Präd}}(k)$, die durch das Trajektorienprädiktionsmodell berechnet wird, wird als maximale Geschwindigkeit des NAFs $v_{\mathrm{NAF}}(k)$ angenommen. Die Aufteilungsposition mit den geringsten Kosten wird ausgewählt und an die zentralisierte Kolonnenregelung weitergeleitet. Dadurch, dass das NAF nicht von dem KF gesteuert werden kann, wird in jedem Zeitschritt eine Aufteilungsposition berechnet, bis das NAF erfolgreich den Fahrstreifen gewechselt hat und die Fahrzeuge hinter dem NAF von der Kolonne getrennt werden.

Zur Veranschaulichung des Manövers wird in Abbildung 6.20 ein Szenario anhand der Simulationsergebnisse dargestellt, in der die Fahrzeugpositionen, die zurückgelegten Strecken aller Kolonnenfahrzeuge und des NAFs sowie die Beschleunigungen, Geschwindigkeiten, Abstände und die Aufteilungsposition über die Zeit aufgetragen sind.

Sobald sich ein NAF der Kolonne nähert und den Fahrtrichtungsanzeiger aktiviert, beginnt die Berechnung der Aufteilungsposition und der Vergrößerung des Abstands erst, wenn der Abstand zwischen dem NAF und dem KF der Länge der Kolonne entspricht. Zu diesem Zeitpunkt wird die zurückzulegende Strecke des NAFs prädiziert. Im vorliegenden Beispiel wurde das NAF bereits ab 1355 s detektiert, ab 1362 s wurde eine Aufteilungsposition 1 berechnet. Dies bedeutet, dass die optimale Position zum Einsortieren des NAFs zwischen KF und FF1 liegt und deren Abstand

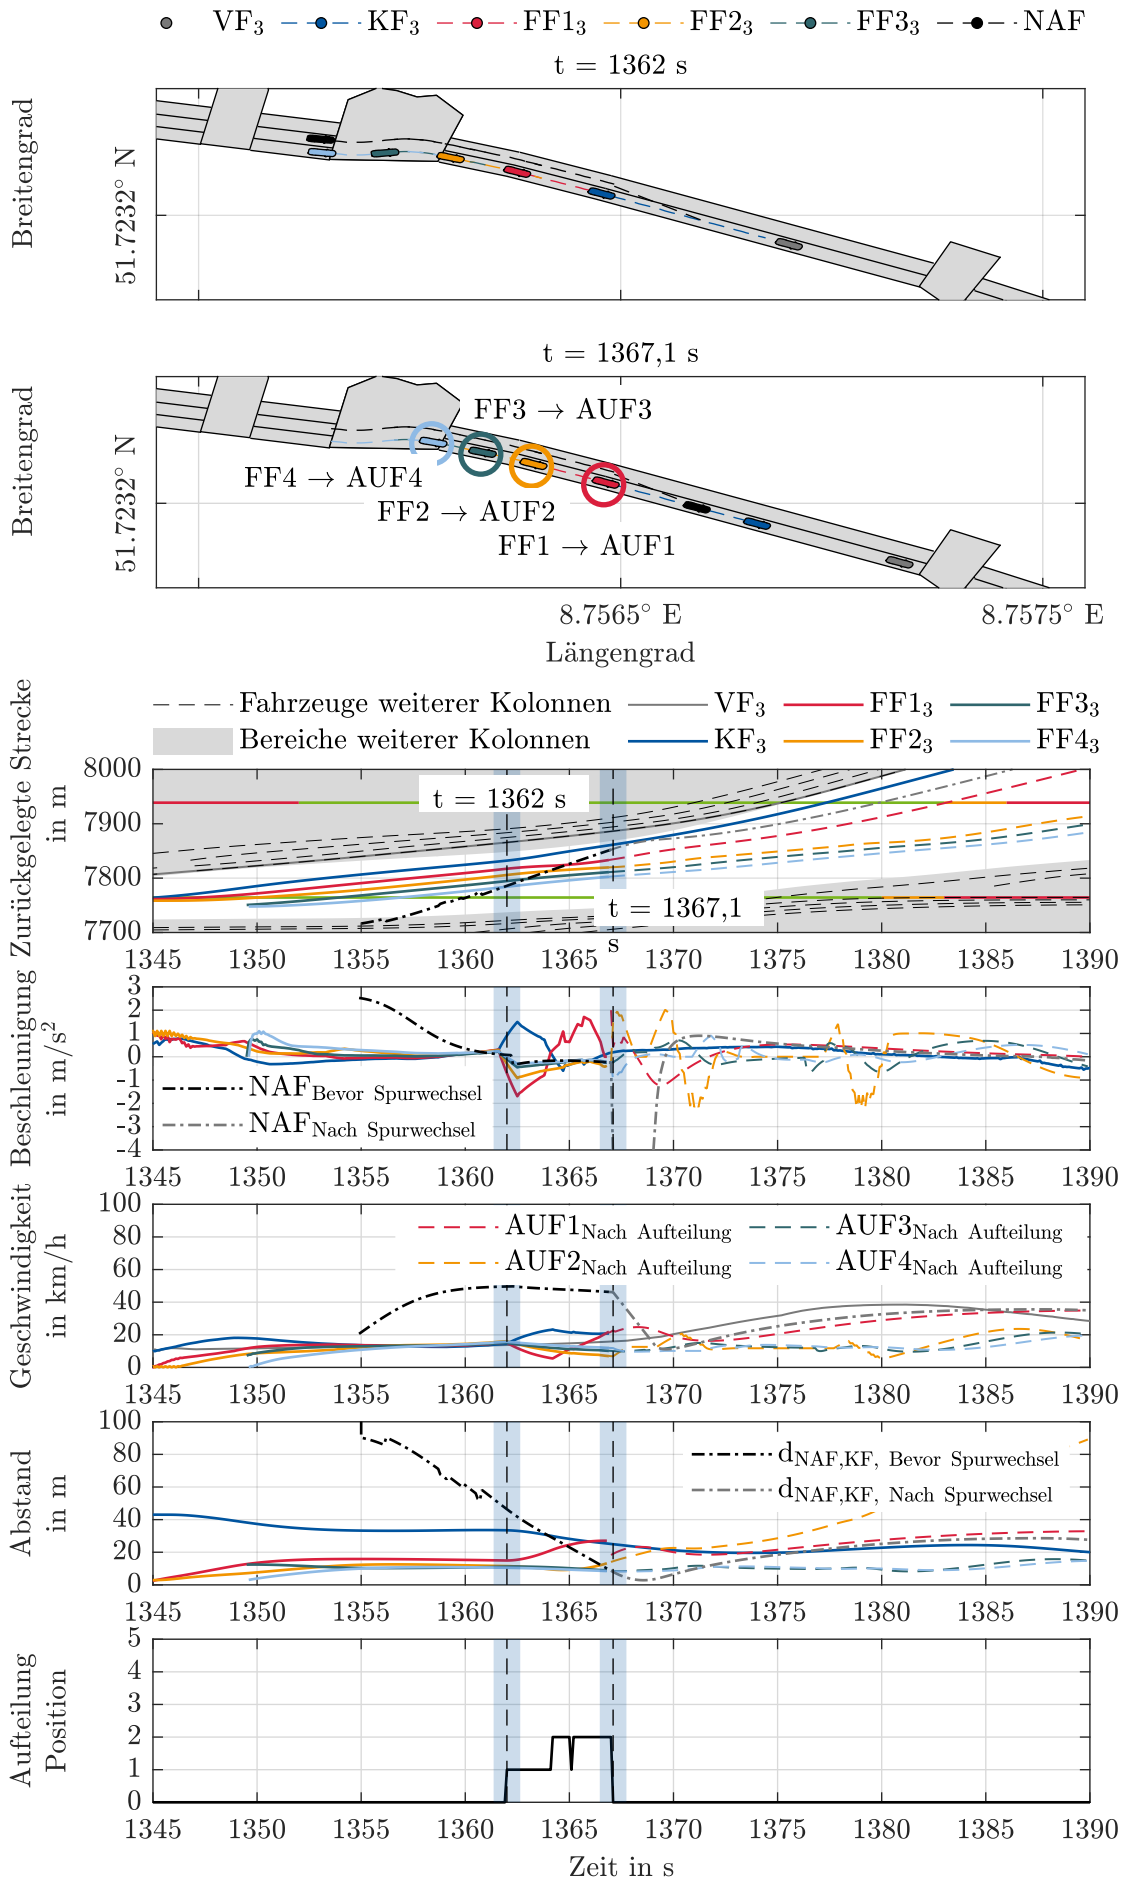

Abbildung 6.20: Auswertung der Simulationsergebnisse für ein beispielhaftes Aufteilungsmanöver durch ein NAF

vergrößert wird. Während der KF die Geschwindigkeit erhöht, verringern FF1 und FF2 diese. Bei 1364,2 s wechselt die optimale Aufteilungsposition von eins auf zwei. Infolgedessen beginnt das FF1 zu beschleunigen. Bei 1367,1s beträgt der Abstand zwischen KF und FF1 27 m und zwischen FF1 und FF2 12,8 m. Das NAF hat sich dafür entschieden, diese Gelegenheit zu nutzen, um den Fahrstreifen zu wechseln und sich zwischen KF und FF1 mit dem größeren Abstand einzusortieren. Dabei verzögert das NAF mit -4.5 m/s^2 bis die Geschwindigkeit auf 11 km/h reduziert ist. Der Abstand zwischen dem NAF und KF reduziert sich auf 3 m. Gleichzeitig werden FF1 bis FF4 aus der Kolonne entfernt und deren IDM - Fahrermodelle übernehmen die Geschwindigkeitsregelung. Nach dem Fahrstreifenwechsel des NAFs folgt dies dem KF und setzt die Fahrt fort. Während dieser Zeit kann kein AUF auf den KF aufschließen, bis das NAF den Fahrstreifen wieder wechselt. Aufgrund der

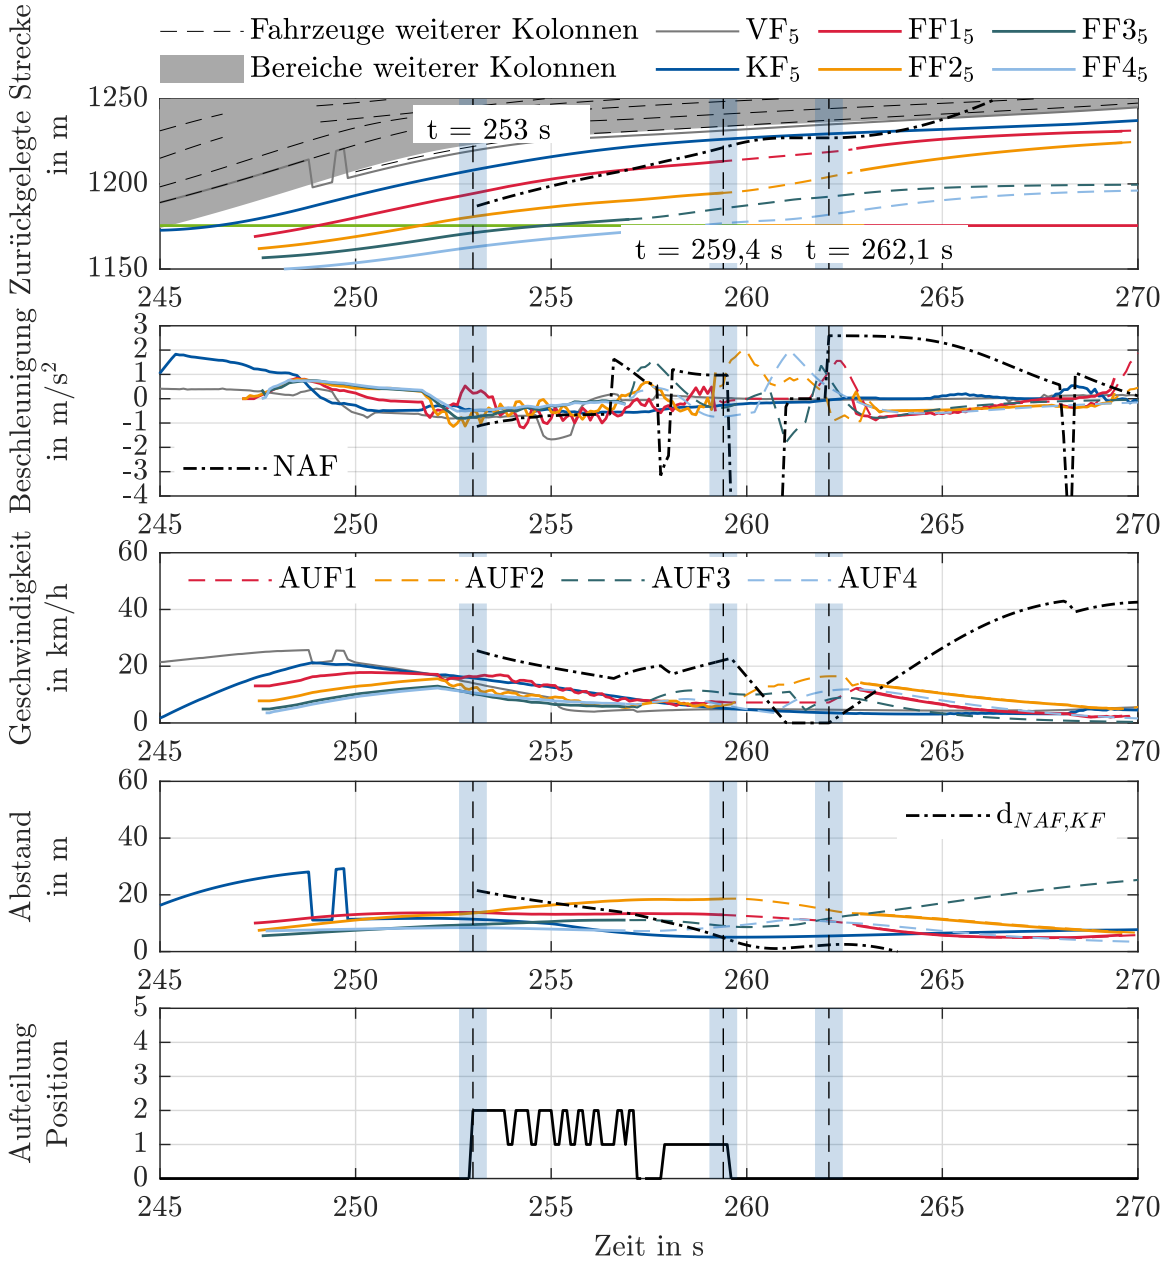

Abbildung 6.21: Auswertung der Simulationsergebnisse für ein beispielhaftes Aufteilungsmanöver durch NAF ohne Fahrstreifenwechsel

Tatsache, dass ein NAF nicht von einer zentralisierten Kolonnenregelung aufgenommen und gesteuert werden kann, kann es vorkommen, dass sich die Entscheidung bezüglich eines Fahrstreifenwechsels ändert. Eine solche Situation wird in Abbildung 6.21 veranschaulicht.
Ein NAF wurde bei 253 s von der Kolonne detektiert und die berechnete mögliche Aufteilungsposition variiert zwischen eins und zwei. Infolgendessen schwanken die Beschleunigungen von FF1 und FF2 ebenfalls. Dies ist auf die Anpassung der Gewichtung für das Kolonnenfahrzeug hinter der Aufteilungsposition gemäß Gleichung 6.19 zurückzuführen, wodurch der Abstand für das NAF durch eine schnelle Änderung der Geschwindigkeit erreicht werden kann. Während dieser Phase wurde der Abstand zwischen dem KF und FF1 sowie zwischen FF1 und FF2 vergrößert.
Bei 259,4 s beschließt das NAF den Fahrstreifen zu wechseln. Nach 2,8 s ändert das NAF jedoch die Entscheidung und bricht den Fahrstreifenwechsel ab, bleibt auf dem ursprünglichen Fahrstreifen und überholt die Kolonne. Infolgedessen werden AUF1 und AUF2 wieder in die Kolonne aufgenommen und erneut zu FF1 und FF2.
In beiden Simulationsergebnissen ist zu beobachten, das ein NAF, das sich mit einer relativ hohen Geschwindigkeit der Kolonne nähert, die Entscheidung für ein Fahrstreifenwechsel trifft, sobald einer der Abstände zwischen zwei Kolonnenfahrzeugen ausreichend groß ist. Das NAF bremst mit einer Verzögerung von bis zu -4,5 m/s^2, was einer Notbremsung nahe kommt. Dieses Verhalten ergibt sich aus dem SUMO Fahrermodell und kann auch durch Einstellung der Fahrstreifenwechsel-Parameter nicht komplett vermieden werden. Zudem beeinflusst die Genauigkeit des im Kapitel 5 beschriebenen Prädiktionsmodells die Zustände aller Kolonnenfahrzeuge. Das in dieser Dissertationsschrift beschriebene Aufteilungsmanöver ermöglicht dennoch den Fahrstreifenwechsel eines NAF und verhindert so eine Blockierung der Fahrbahn durch automatisierte Kolonnenfahrzeuge.

6.3.5 Koordination der Fahrmanöver

Im städtischen Verkehr sind aufgrund der Verkehrssituation komplexere Fahrszenarien möglich, die gleichzeitig mehrere Fahrmanöver erfordern. Beispielweise können Wechsel von einer zweispurigen auf eine einspurige Fahrbahn zu Fahrstreifenwechseln von mehreren AF und NAF führen, während die Kolonne durch das Schaltprogramm der LSA aufgeteilt werden muss. Eine unpassende Koordination der Fahrmanöver kann zur gegenseitigen Blockierung der Fahrzeuge führen und den Verkehrsfluss beeinträchtigen. Um solche Situationen zu bewältigen, ist es notwendig, alle Kolonnenfahrzeuge effektiv und einheitlich zu koordinieren. Dafür werden die in Abschnitten 6.3.1 bis 6.3.4 beschriebenen Fahrmanöver durch das KF zentral koordiniert und kontrolliert durchgeführt. Abbildung 6.22 zeigt das Flussdiagramm zur koordinierten Durchführung aller Fahrmanöver durch den KF.
Das Koordinationsflussdiagramm beginnt mit der Überprüfung, ob ein Aufteilungsmanöver aufgrund einer LSA notwendig ist. Dies hat die höchste Priorität, denn das Überqueren einer LSA während einer Rotphase ist unzulässig. Falls eine Aufteilung erforderlich ist, wird das Manöver umgehend durchgeführt, und es sind keine weiteren Fahrmanöver, abgesehen vom Ausscheren, erlaubt, bis die Kolonne die Kreuzung passiert hat.
Falls kein Aufteilungsmanöver erforderlich ist, wird als nächstes überprüft, ob ein Aufschließ- oder Ausscher-Manöver notwendig ist. Diese beiden Manöver können gleichzeitig durchgeführt werden,

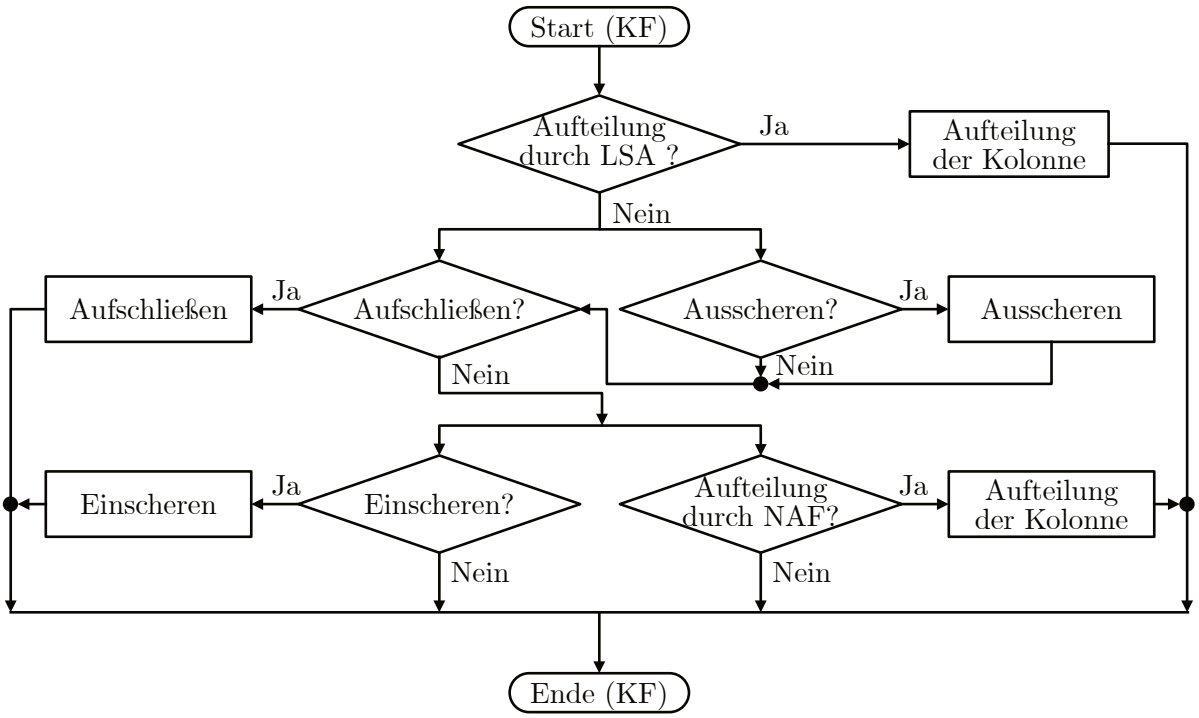

Abbildung 6.22: Schematische Darstellung der Koordination aller Fahrmanöver

sofern die Bedingungen dafür erfüllt sind. Sollte ein Ausscher-Manöver erforderlich sein, wird dieses durchgeführt, andernfalls wird kein Fahrzeug aus der Kolonne aussortiert. Die Durchführung weiterer Fahrmanöver ist unabhängig davon, ob das Ausscher-Manöver ausgeführt wird oder nicht. Ist hingegen ein Aufschließen-Manöver notwendig, wird dieses durchgeführt und währenddessen sind keine Einscher- oder Aufteilungsmanöver durch NAF erlaubt. Die Durchführung von Einscher- oder Aufteilungsmanövern durch NAF erfolgt nur, wenn kein Aufschließ-Manöver erforderlich ist. Aufgrund deren negativen Auswirkungen auf den Energiebedarf der Kolonnenfahrzeuge wird diesen Manövern die niedrigste Priorität zugewiesen, es sei denn, es handelt sich um einen Fahrstreifenwechsel von einer zweispurigen auf eine einspurige Fahrbahn, der für die Weiterfahrt auf der geplanten Route notwendig ist. Aufgrund der begrenzten Anzahl von maximal fünf Kolonnenfahrzeugen und einer durchschnittlichen Dauer von 3 s für das Aufschließ-Manöver ist das Risiko einer Blockierung der Fahrbahn gering.

Um die Auswirkung sämtlicher Fahrmanöver auf den Energiebedarf und den Verkehrsfluss zu analysieren, werden die Simulationsergebnisse im Kapitel 7 ausgewertet und diskutiert.

7 Auswertung der kooperativen Fahrfunktion

Um die im vorherigen Abschnitt dargelegte kooperative Fahrfunktion und das Fahrmanövermanagement in den in Kapitel 4.4 ausgeführten realitätsnahen Verkehrsszenarien zu evaluieren, werden in unterschiedlichen Simulationen jeweils fünf Kolonnenführer mit denselben Anfangspositionen initiiert. Diese folgen während der Simulation einer zuvor definierten Route. Jedes Fahrzeug, das über Kommunikationsfähigkeiten verfügt, kann in die Kolonne integriert werden. Zur quantitativen Bewertung und zum Vergleich der kooperativen Fahrfunktion wird die Referenzstrategie des IDM-Fahrermodells herangezogen.
Zunächst wird in diesem Abschnitt eine mikroskopische Bewertung präsentiert, die insbesondere auf das Fahrverhalten und den damit verbundenen Energiebedarf fokussiert. Anschließend wird eine makroskopische Analyse durchgeführt, welche den Einfluss der kooperativen Fahrfunktionen auf den Energiebedarf aller Fahrzeuge in der Simulation und den Verkehrsfluss dargestellt. Hierdurch ist es möglich, die systemischen Auswirkungen der kooperativen Fahrfunktionen auf das gesamte Verkehrssystem umfassend zu evaluieren.

7.1 Mikroskopische Auswertung der kooperativen Fahrfunktion

In den Simulationen, bei denen die Referenzstrategie zur Anwendung kommt, wird keine Bildung von Fahrzeugkolonnen vorgenommen. Für eine detaillierte mikroskopische Analyse des Fahrverhaltens sowie des Energiebedarfs im Vergleich zu den Kolonnenfahrzeugen mit der Referenzstrategie wird folgender Ansatz angewandt. Es werden bis zu vier aufeinanderfolgende Fahrzeuge identifiziert, die unmittelbar hinter dem KF fahren, sofern solche Fahrzeuge im gegebenen Szenario existieren. Diese maximal fünf Fahrzeuge bilden eine virtuelle Kolonne. Diese Virtualisierung ermöglicht es, eine vergleichbare Basis zu schaffen, auf welcher die Effizienz und Funktionalität eines einzelnen Kolonnenfahrzeugs gesteuert und dem entwickelten Algorithmus mit der Referenzstrategie gegenübergestellt werden kann.

7.1.1 Auswertung des Fahrverhaltens

Aufgrund der identischen Parametrisierung der zentralisierten Kolonnenregelung in Simulationen mit verschiedenen Verkehrsaufkommen erfolgt zur Evaluation des Fahrzeugverhaltens eine Zusammenfassung der Fahrzeugzustände einzelner Kolonnenfahrzeuge aus Simulationen, die unterschiedliche Verkehrsszenarien und -aufkommen berücksichtigen. Das Geschwindigkeits- und Beschleunigungsverhalten werden in den nachfolgenden Abbildungen 7.1 dargestellt.
Bei der Regelung der Fahrzeuge KF bis FF4 mittels der Referenzstrategie finden sich zwei signifikante Bereiche mit erhöhter Häufigkeit. Der erste Bereich ist die Stillstandphase, in der sowohl Geschwindigkeit als auch Beschleunigung einen Wert von Null aufweisen. Zusätzlich wird ein zweiter Bereich in einem Geschwindigkeitsintervall von 40 bis 50 km/h mit moderater Beschleunigung und Verzögerung beobachtet. Diese Häufigkeitsverteilung entspricht der Erwartung für ein nicht vor-

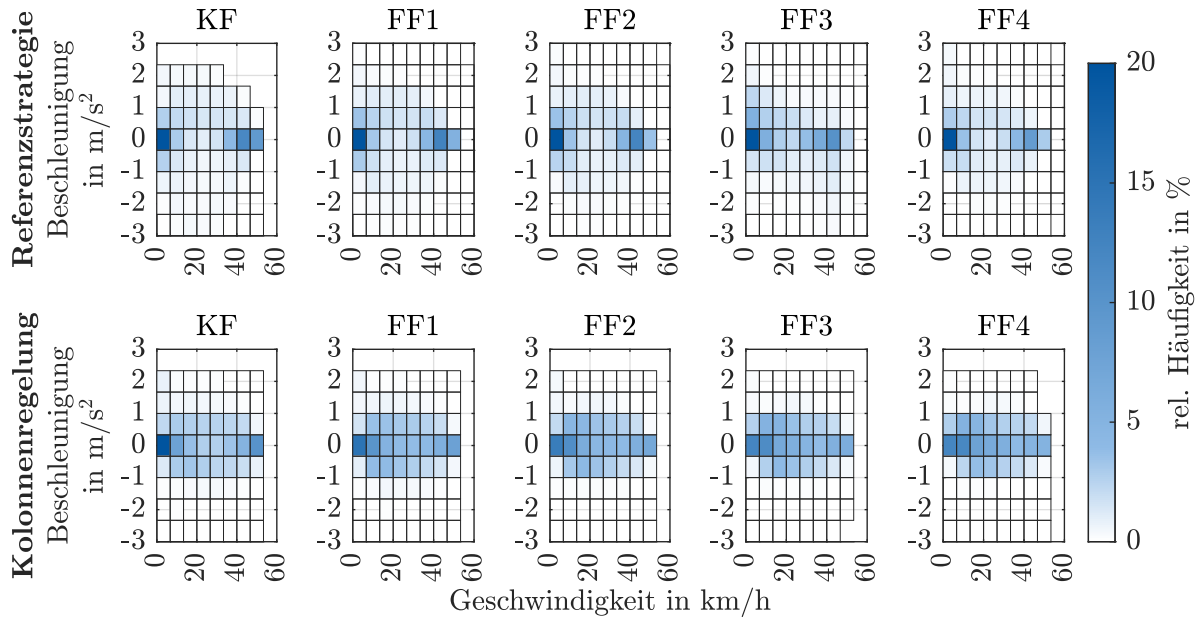

Abbildung 7.1: Darstellung der Histogramme der Beschleunigung in Abhängigkeit der Geschwindigkeit von allen Kolonnenfahrzeugen

ausschauendes Fahrverhalten im urbanen Verkehrsumfeld, welches durch alternierende Fahrphasen zwischen Geschwindigkeiten von annähernd 50 km/h und Stillstand infolge der Rotphase einer LSA gekennzeichnet ist.

Die Analyse der Häufigkeitsverteilung von Fahrzeugbeschleunigungen und -geschwindigkeiten unter Verwendung der zentralisierten Kolonnenregelung legt nahe, dass sich die Werte des KFs ebenfalls in zwei Bereichen befinden. Der erste Bereich ist die Stillstandphase, während der zweite durch eine konstante Geschwindigkeit von etwa 50 km/h gekennzeichnet ist. Der Unterschied zur Verteilung mit der Referenzstrategie besteht darin, dass zwischen 5 bis 50 km/h eine annähernde Gleichverteilung der Geschwindigkeit mit moderater Beschleunigung vorliegt. Bei den Fahrzeugen FF1 bis FF4 zeigt sich ebenfalls eine Geschwindigkeitsverteilung im Bereich von 5 bis 50 km/h mit einer nahezu gleichmäßigen Verteilung. In diesem Zusammenhang sind zwei wesentliche Unterschiede zu den Ergebnissen der Referenzstrategie erkennbar. Bei der zentralisierten Kolonnenregelung treten deutlich weniger ausgeprägte Beschleunigungs- und Verzögerungsmanöver auf. Bei Geschwindigkeiten unter 7 km/h kann eine Beschleunigung von 2 m/s^2, welche der maximal zulässigen Beschleunigungslimitierung entspricht, mit einer Häufigkeit von weniger als 0,84 % beobachtet werden. Oberhalb von 7 km/h liegen die Beschleunigungswerte nahezu ausschließlich unter 0,75 m/s^2. Im Gegensatz dazu sind die Verzögerungswerte fast ausschließlich geringer als -0,75 m/s^2, obwohl die Begrenzung für maximale Verzögerung bei -8 m/s^2 definiert ist. Der zweite Unterschied betrifft die Verteilung der Fahrzeuggeschwindigkeiten. Die Geschwindigkeiten zwischen 5 und 50 km/h sind nahezu gleichverteilt, was auf eine optimierungsbasierte Reaktion der Kolonnenfahrzeuge auf Geschwindigkeitsänderungen des VFs hindeutet. Dies bedeutet, dass die Kolonnenfahrzeuge nicht unmittelbar beschleunigen oder verzögern, wenn das VF die Geschwindigkeit verändert, was auf die Prädiktion des VFs und der eigenen Fahrtrajektorien zurückzuführen ist. Im Vergleich zur Referenzstrategie deuten diese Ergebnisse auf ein antizipatorisches Fahrverhalten hin, welches durch die frühzeitigen Anpassungen der

Geschwindigkeit sichtbar wird.
Bei der Gegenüberstellung der Häufigkeitsverteilungen von FF1 bis FF4 mit denen des KFs lässt sich feststellen, dass die Häufigkeit der Stillstandsphasen bei den FF geringer ist als beim KF. Dies deutet darauf hin, dass die optimierungsbasierte Geschwindigkeitsregelung der FF unnötige Stillstandsphasen effektiv minimiert. Beim Vergleich der Anfahrbeschleunigungen bei Geschwindigkeiten unter 7 km/h zwischen dem KF und FF1 bis FF4 wird ersichtlich, dass mit steigender Fahrzeugposition in einer Kolonne die Anfahrbeschleunigung abnimmt. Im Gegensatz dazu weisen FF1 bis FF4 ähnliche Verzögerungswerte wie das KF auf und diese liegen im Bereich von 0 bis -0,75 m/s^2.
Neben der Analyse des Beschleunigungs- und Geschwindigkeitsverhaltens wird das Folgefahrtverhalten der Fahrzeuge in einer Kolonne durch die zweidimensionale Häufigkeitsverteilung der relativen Geschwindigkeit in Korrelation zum Abstand in Abbildung 7.2 veranschaulicht.

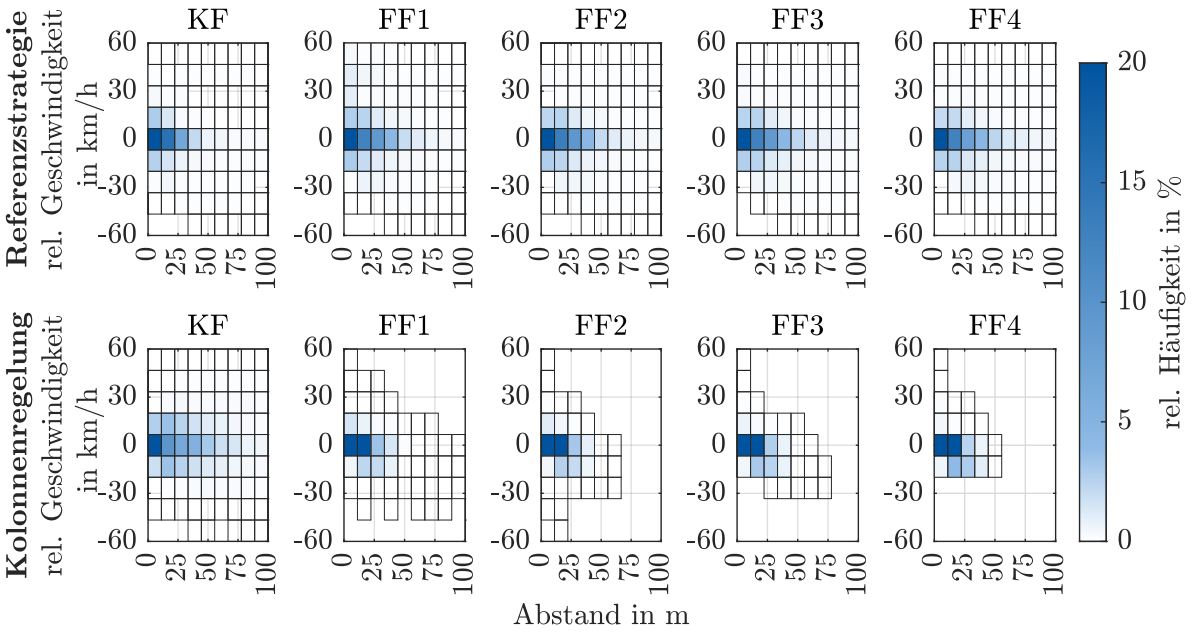

Abbildung 7.2: Darstellung der Folgeverhalten mithilfe von Histogrammen der relativen Geschwindigkeit und des Abstands von allen Kolonnenfahrzeugen

Die Analyse der mittels der Referenzstrategie gesteuerten Fahrzeuge stellt dar, dass diese überwiegend mit einem Abstand von weniger als 30 m und einer relativen Geschwindigkeit im Bereich von ± 15 km/h folgen. Dieses Verhalten entspricht den Eigenschaften des IDM-Fahrermodells, welches einen konstanten Zeitabstand regelt und kann sowohl bei den KF als auch FF beobachtet werden. Dies ist darauf zurückzuführen, dass die Referenzstrategie keine spezifische FF-Regelung aufweist und daher keine signifikante Verbesserung des Folgeverhaltens in den FF bewirkt.
Bei Fahrzeugen, die durch die zentralisierte Kolonnenregelung gesteuert sind, ist eine signifikante Veränderung im Folgeverhalten ersichtlich. Bei der Analyse der Häufigkeitsverteilung des KFs kann festgestellt werden, dass diese Fahrzeuge dazu neigen, dem VF in einem Intervall von 5 bis 50 m und einer relativen Geschwindigkeit von -15 bis 15 km/h zu folgen. Die positive relative Geschwindigkeit, auch bei größeren Abständen, kann als Indikation für eine schnellere Beschleunigung und demzufolge zügiger erreichbare Höchstgeschwindigkeiten des VFs interpretiert werden. Negative relative Geschwindigkeit tritt hingegen auf, wenn das VF verzögert und die KF deren Geschwindigkeit, auf-

grund der Prädiktion und Optimierung, anders als bei der Referenzstrategie, nicht sofort ändern. Dieses Verhalten kann durch die Gewichtung der Verzögerung in der Kostenfunktion erklärt werden. Währenddessen reduziert sich der Abstand zwischen dem KF und VF, wobei die minimalen Abstandsbegrenzungen stets eingehalten werden. Im Vergleich zur Referenzstrategie erlaubt die optimierungsbasierte Kolonnenregelung dem KF, größere Abstände zum VF zu halten und somit bei Veränderungen der Fahrgeschwindigkeit des VFs nicht sofort darauf reagieren zu müssen.
Bei der Betrachtung der FF zeigt sich eine begrenzte Häufigkeitsverteilung der relativen Geschwindigkeit im Verhältnis zum Abstand, welche für FF1 bis FF4 im Bereich von -10 bis 10 km/h und 5 bis 25 m liegt. Dieser Bereich verringert sich von FF1 bis FF4. Dies korrespondiert mit der Parametereinstellung der zentralisierten Kolonnenregelung, bei der der Referenzzeitabstand der FF niedriger als der der KF definiert ist.
Basierend auf einer vergleichenden Analyse unter Einsatz der Referenzstrategie kann festgestellt werden, dass der Verteilungsbereich, sowohl der relativen Geschwindigkeit als auch des Abstands, verringert ist. Die FF werden trotz geringerer Abstände nicht signifikant durch das jeweilige VF beeinflusst, weil das VF ebenfalls ein Kolonnenfahrzeug ist und durch die zentralisierte Kolonnenregelung gesteuert wird. Sowohl jetzige als auch prädizierte zukünftige Fahrzeugzustände aller Kolonnenfahrzeuge werden in einer Kostenfunktion berücksichtigt. Für die Lösung des Optimierungsproblems wird demnach nicht ausschließlich der Zustand eines einzelnen Fahrzeugs optimiert. Vielmehr wird ein ganzheitlicher Ansatz verfolgt, bei dem die Zustände sämtlicher Fahrzeuge evaluiert werden. Dadurch wird es ermöglicht, den Abstand zwischen den Fahrzeugen minimal zu halten, ohne negative Auswirkungen auf das Fahrverhalten zu haben. Abschließend lässt sich zusammenfassen, dass die FF mit reduziertem Abstand und geringerer relativer Geschwindigkeit dem jeweiligen vorausfahrenden Fahrzeug folgen können, das einem optimierten Folgeverhalten entspricht.

7.1.2 Auswertung des Energiebedarfs

Gemäß Tabelle A.1.4 wurde in der Simulationsumgebung eine realitätsnahe Verteilung der Fahrzeugklassen implementiert. Unter der Annahme, dass 85 % aller Fahrzeuge in der Simulationsumgebung kommunikationsfähig und für die Integration in eine Kolonne qualifiziert sind, ergibt sich daraus eine variierende prozentuale Zusammensetzung der Fahrzeugklassen innerhalb einer gegebenen Kolonne. Zum energetischen Vergleich der in der Kolonne befindlichen Fahrzeuge, sowohl untereinander als auch in Relation zur Referenzstrategie, ist eine Normierung des Energiebedarfs erforderlich. Hierbei wird der Energiebedarf der in der Kolonne befindlichen Fahrzeuge durch den in Tabelle A.1.4 spezifizierten WLTC-Energiebedarf dividiert und mit dem Wert der Fahrzeugklassen Mini, Kleinwagen und Kompaktwagen von 15,5 kWh/100 km multipliziert. Diese Methode gewährleistet eine normierte Energiebedarfskalkulation, die eine valide vergleichbare Analyse ermöglicht.
Für eine präzise Ermittlung des Energiebedarfs der Kolonnenfahrzeuge ist zu berücksichtigen, dass kommunikationsfähige Fahrzeuge in der Simulation, abhängig vom Ein- oder Austrittszeitpunkt in die Kolonne, unterschiedliche Geschwindigkeiten und folglich eine variierende potenzielle Energie aufweisen können. Diese Abweichungen müssen in der Energiebedarfskalkulation entsprechend addiert oder subtrahiert werden.

Zur Erstellung quantitativer und weitgehend von stochastischen Einflüssen befreiter Aussagen bezüglich des Verhältnisses des durchschnittlichen Energiebedarfs zur durchschnittlichen Geschwindigkeit werden Analysen aller Kolonnenfahrzeuge von KF bis FF4, jeweils über zehn unterschiedliche Verkehrssimulationen, durchgeführt.Diese Untersuchungen erfolgen separat für die maximalen Fahrzeuganzahlen von 200, 250 und 300 Fahrzeugen. Demzufolge stehen für die jeweiligen Verkehrsaufkommen Auswertungen von ungefähr 598 km Fahrstrecke für KF bis hin zu 53 km Fahrstrecke für FF4 zur Verfügung.

Tabelle 7.1: Energiebedarf und durchschnittliche Geschwindigkeit der zentralisierten Kolonnenregelung und der Referenzstrategie bei unterschiedlichen Verkehrsdichten

$n_{\mathrm{Fzg,max}}$	Fahrzeug	$\bar{v}_{\mathrm{Fzg}}$ in km/h			$\bar{E}_{\mathrm{Fzg}}$ in kWh/100 km		
		Ref.	Kolonnenregelung		Ref.	Kolonnenregelung	
200	KF	25,08	23,75	-5,29 %	9,40	8,18	-12,99 %
	FF1	24,22	24,26	0,16 %	9,49	8,48	-10,61 %
	FF2	26,52	23,77	-10,36 %	9,46	9,13	-3,50 %
	FF3	26,80	23,22	-13,36 %	9,37	9,53	1,86 %
	FF4	26,63	22,79	-14,40 %	9,20	10,20	10,91 %
250	KF	19,95	21,18	6,14 %	9,89	8,39	-15,17 %
	FF1	19,26	21,94	13,91 %	9,27	8,45	-8,78 %
	FF2	21,24	21,70	2,15 %	9,55	8,74	-8,45 %
	FF3	21,06	21,11	0,27 %	9,26	8,46	-8,56 %
	FF4	21,33	20,44	-4,17 %	9,31	8,92	-4,26 %
300	KF	17,69	19,67	11,21 %	10,03	8,49	-15,35 %
	FF1	18,33	20,75	13,15 %	9,36	8,28	-11,58 %
	FF2	18,43	20,52	11,33 %	9,56	8,44	-11,72 %
	FF3	18,52	20,08	8,41 %	8,97	8,64	-3,71 %
	FF4	18,63	21,65	16,20 %	8,59	8,99	4,71 %

In Tabelle 7.1 sind der ausgewertete streckenbezogene Energiebedarf und die Geschwindigkeit aufgelistet, in der Abbildung 7.3 wird dies veranschaulicht.
Wie bereits in Abbildung 4.7 dargestellt, entsteht bei einer maximalen Anzahl von 200 Fahrzeugen in der Simulationsumgebung ein tendenziell frei-fließender Verkehrszustand. Mit einer Erhöhung der maximalen Fahrzeuganzahl auf 250 und 300 zeigt das Verhältnis zwischen Verkehrsstärke und Verkehrsdichte ein Übergang hin zu stärker gebundenem und schließlich gestautem Verkehrsverhalten. Dieses Verhalten wird auch in Abbildung 7.3 deutlich. Die durchschnittliche Geschwindigkeit der Fahrzeuge in der Kolonne nimmt sowohl bei Verwendung der Referenzstrategie als auch der zentralisierten Kolonnenregelung mit zunehmender Fahrzeuganzahl ab.
Wird die zentralisierte Kolonnenregelung für Fahrzeuge in einem freien Verkehrszustand, z. B. mit einer maximalen Anzahl von 200 Fahrzeugen, in der Simulationsumgebung eingesetzt, zeigt sich eine Reduktion der durchschnittlichen Geschwindigkeiten von KF bis FF4 um bis zu 14,40 %. Bei Anwendung der Referenzstrategie variieren die Geschwindigkeiten im Intervall von 24,22 bis 26,80 km/h und bei den Fahrzeugen, die mit der Kolonnenregelung gesteuert sind, liegen diese Werte zwi-

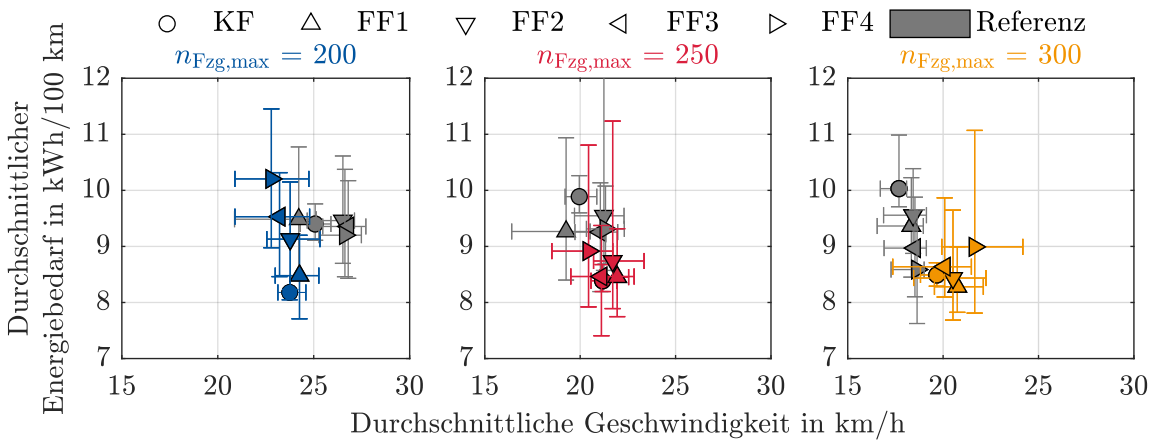

Abbildung 7.3: Darstellung der Folgeverhalten mithilfe der relativen Geschwindigkeit und des Abstands von allen Kolonnenfahrzeugen

schen 22,79 und 24,26 km/h. Hierbei ist zu beachten, dass eine Reduzierung der durchschnittlichen Geschwindigkeit nicht zwangsläufig zu einer Reduzierung des Energiebedarfs führt. Das Energieeinsparpotenzial vom KF liegt bei 12,99 %, wohingegen bei FF4 eine Erhöhung des Energiebedarfs von 10,91 % im Vergleich zur Referenzstrategie festgestellt wird.

Die reduzierte durchschnittliche Geschwindigkeit lässt sich hauptsächlich auf die durch die Optimierung verringerte Beschleunigung der Fahrzeuge zurückführen. Infolgedessen tendiert ein KF dazu, eine spätere Grünphase einer LSA für das Passieren einer Kreuzung zu präferieren. Diese Auswahl resultiert in einer verlängerten Gesamtreisezeit der Kolonne, wodurch sich bei konstanter Fahrstrecke die durchschnittliche Geschwindigkeit der Kolonne entsprechend reduziert.

Unter freien Verkehrsbedingungen werden Fahrzeuge, die mittels Aufschließ- und Einscher-Manöver in die Kolonne eingegliedert werden, in größerem Abstand erkannt. Bei Anwendung der Referenzstrategie ermöglicht dieser ausreichend große Abstand zwischen den Fahrzeugen die Durchführung von Manövern, ohne die Zustände anderer Verkehrsteilnehmer signifikant zu beeinträchtigen. Im Gegensatz dazu führt die Kostenfunktion bei Anwendung der zentralisierten Kolonnenregelung während des Aufschließens weiterer Fahrzeuge mit großem Abstand zu einer Minimierung des Abstands. Infolgedessen beschleunigt das nachfolgende Fahrzeug, während das vorausfahrende Fahrzeug dessen Geschwindigkeit reduziert. Beim Einscheren wird der notwendige Abstand durch Verzögerung der Kolonnenfahrzeuge vergrößert. Daher wird der Energiebedarf des AFs, EFs und der Kolonnenfahrzeuge, insbesondere bei den Aufschließ- und Einscher-Manövern, negativ beeinflusst. In einer gesamtheitlichen Betrachtung zeigt sich eine Erhöhung des Energiebedarfs von KF bis FF4. Auch wenn die zentralisierte Kolonnenregelung insgesamt den Energiebedarf gegenüber der Referenzstrategie um 2,92 % reduziert, übersteigt der Energiebedarf ab dem Fahrzeug FF3, bedingt durch die Fahrmanöver, den entsprechenden Wert der Referenzstrategie.

Bei Anwendung der zentralisierten Kolonnenregelung in gebundenen Verkehrsbedingungen, exemplarisch dargestellt durch eine Simulationsumgebung mit einer maximalen Anzahl von 250 bzw. 300 Fahrzeugen, lassen sich signifikante Veränderungen sowohl in der durchschnittlichen Geschwindigkeit als auch im Energiebedarf beobachten. Die Auswertungen in Tabelle 7.1 sowie Abbildung 7.3 verdeutlichen, dass die durchschnittliche Geschwindigkeit der Fahrzeuge unter Anwendung der

zentralisierten Kolonnenregelung im Vergleich zur Referenzstrategie mit einer maximalen Zunahme von jeweils 13,91 % und 16,20 % ansteigt. Aus den Daten ergibt sich, dass mithilfe der zentralisierten Kolonnenregelung eine Erhöhung der durchschnittlichen Geschwindigkeit bei zunehmendem Verkehrsaufkommen erzielt werden kann. Daraus lässt sich die Schlussfolgerung ableiten, dass die entwickelte Kolonnenregelung dazu beiträgt, den Verkehrsfluss in gebundenen bis hin zu gestauten Verkehrssituationen zu verbessern.

Die Analyse des Energiebedarfs von Fahrzeugen unter Anwendung einer zentralisierten Kolonnenregelung zeigt, dass alle Kolonnenfahrzeuge, mit Ausnahme des FF4 bei einer maximalen Fahrzeuganzahl von 300, in gebundenem und gestautem Verkehr einen geringeren Energiebedarf im Vergleich zur Referenzstrategie aufweisen. Das gesamte Energieeinsparpotenzial aller Kolonnenfahrzeuge liegt zwischen 9,14 % und 7,89 %. Besonders hervorzuheben ist der KF, bei welchem ein Energieeinsparpotenzial von jeweils 15 % identifiziert werden kann.

In Verkehrssituationen, die durch gebundenen Verkehr gekennzeichnet sind, treten häufiger Stop-and-Go-Situationen aufgrund teilweise überlasteter Verkehrsinfrastruktur auf. Bei Anwendung der Referenzstrategie erfolgt eine unmittelbare Beschleunigung oder Verzögerung der Fahrzeuge, sobald das jeweilige VF dessen Geschwindigkeit ändert. Im Gegensatz dazu optimiert die zentralisierte Kolonnenregelung den Zustand der gesamten Fahrzeugkolonne in Abhängigkeit von der aktuellen Verkehrssituation. Das hat zur Folge, dass nicht alle Fahrzeuge in einer Kolonne direkt auf Geschwindigkeitsänderung des jeweiligen VFs reagieren. Wenn beispielsweise das VF einer Kolonne beschleunigt und wieder verzögert, hält der KF einen größeren Abstand und folgt dem VF mit einer annähernd konstanten, niedrigeren Geschwindigkeit. Dadurch werden unnötige Verzögerungsmanöver effizient minimiert, das zu einer merklichen Reduktion des Energiebedarfs führt. Hieraus ergibt sich die Erkenntnis, dass die entwickelte zentralisierte Kolonnenregelung in der Lage ist, den gesamten Energiebedarf aller Kolonnenfahrzeugen bei gebundenen und gestauten Verkehrsbedingungen zu reduzieren.

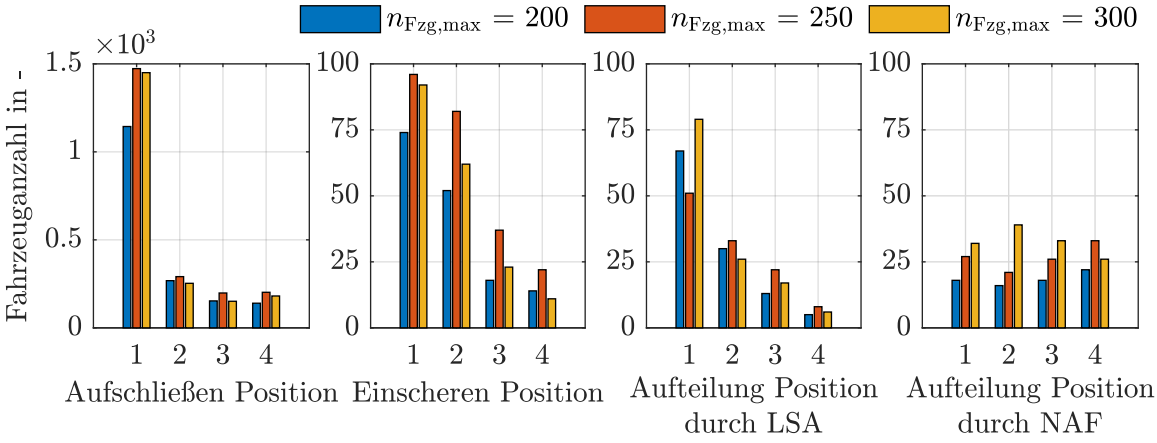

Abbildung 7.4: Darstellung der Häufigkeit von durchgeführten Fahrmanövern in sämtlichen Simulationsszenarien

Abbildung 7.4 visualisiert die Häufigkeit der durchgeführten Fahrmanöver in sämtlichen Simulationsszenarien. In der Abbildung werden die Fahrzeuganzahl und die Positionen von Aufschließ-, Einscher- und Aufteilungsmanövern dargestellt.

Bei der Analyse der Verteilung der Fahrzeugpositionen während der Aufschließ-Manöver wird ersichtlich, dass die Auswahl der Position 1, die unmittelbar hinter dem KF liegt, im Vergleich zu anderen Positionen innerhalb der Kolonne dominiert. Dieses Verhalten kann auf drei Faktoren zurückgeführt werden. Die Verkehrssituation beeinflusst die Struktur der Kolonne. Oftmals besteht die Kolonne lediglich aus einem KF oder zusammen mit einem FF. Wenn ein FF1 die Route ändert und die Kolonne verlässt, kann ein weiteres Fahrzeug wieder die Position des FF1 einnehmen.
In einer weiterführenden Betrachtung liefert das Modell des Fahrstreifenwechsels eine erkenntnisreiche Erklärung. Wenn das KF eine Geschwindigkeitssteigerung mit reduzierter Beschleunigung vollzieht, neigt das FF1 dazu, einen Fahrstreifenwechsel zu initiieren, bedingt durch das Potenzial einer höheren fahrbaren Geschwindigkeit auf dem angrenzenden Fahrstreifen. Nachdem das FF1 die Kolonne verlassen hat, ist es möglich ein weiteres Fahrzeug als neues FF1 in die Kolonne zu integrieren.
Des Weiteren zeigt die Abbildung 7.4, dass die Einscher- und Aufteilungsmanöver häufig bei Position 1 auftreten. Infolgedessen wird die Kolonne regelmäßig an dieser Stelle aufgeteilt. Daraus resultierend wird, sofern es die Verkehrssituation und der Fahrzeugzustand erlauben, ein weiteres Fahrzeug direkt hinter dem KF integriert.
Bei Darstellung der Verteilung der Fahrzeuganzahl während der Aufschließ-Manöver zeigt sich, dass die Anzahl der Fahrzeuge, die bei Position 1 aufschließen, im Bereich zwischen 1144 und 1473 liegt, während für die Positionen 2 bis 4 Werte zwischen 291 und 140 Fahrzeugen erfasst werden. Ein Vergleich dieser Anzahlen über verschiedene Verkehrsaufkommen zeigt, dass die Anzahl der Aufschließ-Manöver bei einer Simulationsumgebung mit 200 Fahrzeugen geringer ist im Vergleich zu Szenarien mit 250 oder 300 Fahrzeugen. Interessanterweise ist die Häufigkeit bei einem Verkehrsaufkommen von 300 Fahrzeugen geringer als bei 250 Fahrzeugen. Weiterhin ist es zu bemerken, dass die Position 3 die niedrigste Häufigkeit aufweist.
Bei einer eingehenden Betrachtung der Einscherpositionen in Abbildung 7.4 wird festgestellt, dass in verschiedenen Verkehrsaufkommen die Positionen 1 und 2 am häufigsten ausgewählt werden. Dieses Verhalten ist maßgeblich durch die Geschwindigkeitsunterschiede zwischen dem benachbarten Fahrzeug und den Kolonnenfahrzeugen bedingt. Häufig weist das EF eine deutlich höhere Geschwindigkeit als die Kolonnenfahrzeuge auf. Das optimierungsbasierte Fahrmanövermanagement tendiert dazu, eine Fahrlücke hinter dem KF und FF1 zu generieren, um das Einscheren zu ermöglichen.
Interessanterweise zeigt eine weitere Analyse der Simulationsdaten, dass bei einem Fahrzeugaufkommen von 250 die größte Anzahl an Fahrmanövern stattfindet. Bei Szenarien mit 300 Fahrzeugen nimmt die Anzahl ab, während diese bei 200 Fahrzeugen am geringsten ist. Diese Verteilung korreliert direkt mit dem in Kapitel 4 beschriebenen Fahrstreifenwechselmodell. Bei freiem Verkehr tendieren die Nicht-Kolonnenfahrzeuge zu freien Fahrten, wodurch deren Geschwindigkeit wenig von vorausfahrenden Fahrzeugen beeinflusst wird. Dadurch, dass die Kolonnenfahrzeuge im Allgemeinen eine niedrigere Beschleunigung und eine frühere Verzögerung aufweisen, neigen benachbarte Fahrzeuge dazu, aufgrund der Geschwindigkeitsunterschiede keinen Fahrstreifenwechsel durchzuführen. In gebundenem Verkehr hingegen wird nicht nur die Geschwindigkeit der Kolonnenfahrzeuge, sondern auch jene der benachbarten Fahrzeuge durch vorausfahrende Fahrzeuge beeinflusst. Angesichts

der Tatsache, dass durch die Kolonnenregelung eine Erhöhung der durchschnittlichen Geschwindigkeit möglich ist, neigen benachbarte Fahrzeuge dazu, einen Fahrstreifenwechsel zu initiieren, wenn deren Geschwindigkeit geringer als die der Kolonnenfahrzeuge ist. Im Szenario des gestauten Verkehrs mit 300 Fahrzeugen reduziert sich die Anzahl der Fahrstreifenwechsel aufgrund der teilweise überlasteten Fahrbahnen. Wenn Fahrzeuge auf beiden Fahrstreifen mit niedriger Geschwindigkeit oder gar im Stillstand agieren, werden aufgrund des Fahrstreifenwechselmodells keine Wechsel hinsichtlich der Verkehrsdichte initiiert. Dies gewährleistet, dass über einen gegebenen Zeitraum die maximale Anzahl an Fahrzeugen die überlastete Straße passieren kann, damit ist die Gesamtzahl der durchgeführten Einscher-Manöver bei 300 Fahrzeugen geringer als bei 250.
Im Gegensatz zu den Einscher-Manövern zeigt die Anzahl der durch NAF initiierten Aufteilungsmanöver keine signifikante Abhängigkeit vom Verkehrsaufkommen. Die gesamte Anzahl der durchgeführten Fahrmanöver ist aufgrund des niedrigeren Anteils der NAF kleiner als die von den Einscher-Manövern. Bezüglich der Positionen, an denen Aufteilungsmanöver durch NAF stattfinden, lässt sich eine annähernd gleiche Verteilung über die Positionen 1 bis 4 feststellen. Dieses Verhalten resultiert hauptsächlich aus der Abhängigkeit der Aufteilungsentscheidung von der prädizierten Fahrgeschwindigkeit des NAFs. Es ist anzumerken, dass die Geschwindigkeitsregelung des NAFs nicht durch die Kolonnenregelung beeinflusst wird. Die Ungenauigkeit in der Geschwindigkeitsprädiktion sowie die daraufhin angepassten Geschwindigkeiten der Kolonnenfahrzeuge führen zu einer Herausforderung in der Bestimmung der optimalen Aufteilungsposition, welche stark von der realen Fahrgeschwindigkeit des betreffenden NAFs abhängig ist.
Bei der Untersuchung des durch die Schaltzeit der LSA initiierten Aufteilungsmanövers lassen sich mehrere Schlüsselaspekte herausstellen. Bei Betrachtung unterschiedlicher Verkehrsaufkommen ist auffällig, dass die Häufigkeit, mit der bestimmte Aufteilungspositionen gewählt werden, nur geringfügige Unterschiede aufweist, dennoch nimmt die Anzahl der Manöver von Aufteilungsposition 1 bis 4 ab. Der Grund für diese Verteilung sind die Schaltzeiten der LSA in Kombination mit der prädizierten Geschwindigkeit des vorausfahrenden Fahrzeugs. Sollte die tatsächliche Geschwindigkeit des VFs signifikant von der prädizierten Geschwindigkeit abweichen, kann es notwendig sein, zusätzliche Fahrzeuge aus der Kolonne zu entfernen. Dies gewährleistet, dass keines der Fahrzeuge während einer Rotphase der LSA eine Kreuzung überquert. Beispielsweise kann initial eine Aufteilungsposition 4 bestimmt werden, wodurch das fünfte Fahrzeug aus der Kolonne entfernt wird. Reduziert das VF der Kolonne unerwartet seine Geschwindigkeit, kann dies zur Entfernung weiterer Fahrzeuge, wie beispielsweise dem vierten, führen. Infolgedessen ist die Häufigkeit der Aufteilungsposition 1 am höchsten.
Ein zusätzlicher Faktor, der diese Verteilung beeinflusst, liegt in der Fahrzeuganzahl innerhalb einer Kolonne. In den simulierten Szenarien besteht eine Kolonne am häufigsten aus nur einem oder zwei Fahrzeugen. Dies impliziert, dass bei einer durch die LSA veranlassten Aufteilung der Kolonne, die Aufteilungsposition 1 mit einer erhöhten Wahrscheinlichkeit herangezogen wird.
Im Rahmen der mikroskopischen Analyse lässt sich feststellen, dass die konzipierte zentralisierte Kolonnenregelung effektiv dazu beiträgt, unerwünschte Beschleunigungs- und Verzögerungsaktionen sämtlicher Fahrzeuge innerhalb einer Kolonne zu minimieren. Ferner ermöglicht diese durch eine

zielgerichtete Geschwindigkeitsanpassung eine Optimierung des streckenabhängigen Energiebedarfs. Das Folgeverhalten von Fahrzeugen zeigt eine Tendenz zu vergrößerten Abständen beim KF und niedrigeren Abständen bei den FF im Vergleich zur Referenzstrategie. Die Abstände beim KF reflektieren ein antizipatorisches Fahrverhalten der Kolonne, während die verkleinerten Abstände bei den FF auf eine Steigerung der Effizienz des Verkehrsflusses hindeuten.
Die Analyse des Energiebedarfs aller Kolonnenfahrzeuge in diversen Verkehrsszenarien stellt dar, dass die durch die zentralisierte Kolonnenregelung erzielten Verbesserungen in Bezug auf den Energiebedarf sowie den Verkehrsfluss insbesondere in gebundenem und gestautem Verkehr signifikant sind.

7.2 Makroskopische Auswertung der kooperativen Fahrfunktion

Die in dem vorangegangenen Abschnitt präsentierten Ergebnisse weisen auf eine signifikante Beeinflussung des Verkehrsflusses durch die zentralisierte Kolonnenregelung hin. Um die potenzielle Auswirkung dieser Regelung auf das gesamte Verkehrssystem zu analysieren, werden sowohl der Energiebedarf als auch die Verkehrsdichte aller Fahrzeuge entlang der für die Kolonnen ausgewählten Strecke evaluiert. Zusätzlich wird, zur exemplarischen Darstellung potenzieller Systemauswirkungen, die Parametrisierung der Kolonnenregelung in einem spezifischen Fahrszenario variiert.

7.2.1 Auswirkung auf den Energiebedarf und die durchschnittliche Geschwindigkeit

In Abbildung 7.5 wird der tatsächliche durchschnittliche Energiebedarf und die Geschwindigkeit aller Fahrzeuge in sämtlichen Verkehrssimulationen zusammengefasst. Hierbei werden die Ergebnisse der zentralisierten Kolonnenregelung mittels gefüllter Kreissymbole und der Referenzstrategie mittels gefüllter Rautensymbole visualisiert.

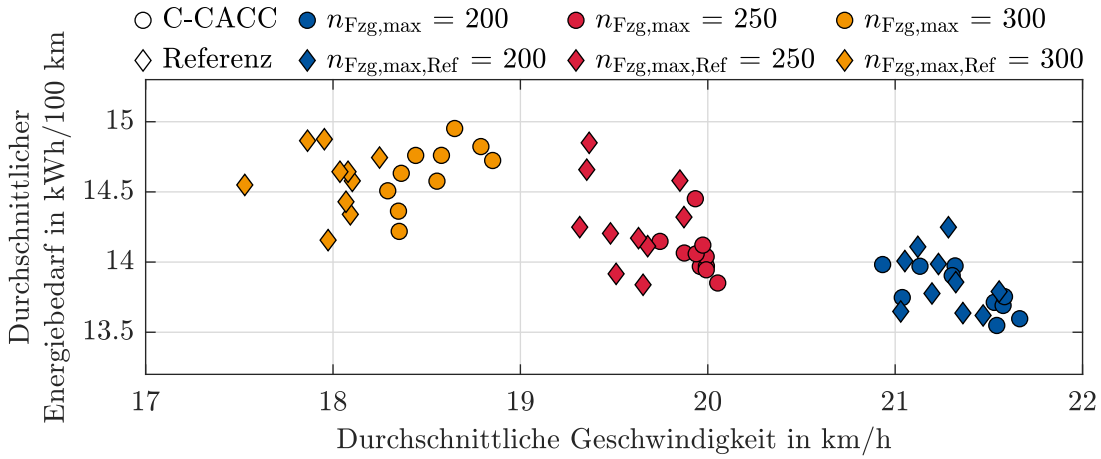

Abbildung 7.5: Darstellung des Energiebedarfs und der durchschnittlichen Geschwindigkeit aller Fahrzeuge bei der maximalen Anzahl von 200, 250 und 300 Fahrzeugen der zentralisierten Kolonnenregelung gegenüber der Referenzstrategie

Bei einer vergleichenden Analyse der Ergebnisse mit der zentralisierten Kolonnenregelung unter Berücksichtigung unterschiedlicher maximaler Fahrzeuganzahlen zeigt sich, dass die durchschnittliche Geschwindigkeit aller Fahrzeuge bei steigenden Verkehrsaufkommen abnimmt. Bei Simulationen mit

maximal 200 Fahrzeugen liegt die durchschnittliche Geschwindigkeit zwischen 20,93 und 21,66 km/h. Dieser Wert reduziert sich auf einen Bereich von 19,75 bis 20,06 km/h bei 250 Fahrzeugen und weiter auf 18,29 bis 18,85 km/h bei 300 Fahrzeugen. Bei einer parallelen Betrachtung des durchschnittlichen streckenbezogenen Energiebedarfs wird ersichtlich, dass der Wert mit steigender Anzahl von maximalen Fahrzeugen steigt. Bei 200 Fahrzeugen liegt der Energiebedarf zwischen 13,55 und 13,98 kWh/100 km, wohingegen dieser bei 250 Fahrzeugen zwischen 13,84 und 14,44 kWh/100 km und bei 300 Fahrzeugen zwischen 14,22 und 14,95 kWh/100 km liegt. Ein vergleichbares Verhalten lässt sich auch bei den Simulationen mit der Referenzstrategie erkennen.
Eine Gegenüberstellung der Ergebnisse aus den Simulationen mit zentralisierter Kolonnenregelung und jenen der Referenzstrategie zeigt, dass der durchschnittliche Energiebedarf in freien und gebundenen Szenarien mit Referenzstrategie höher liegt als bei der Verwendung der zentralisierten Kolonnenregelung. Das Energieeinsparpotenzial variiert dabei je nach maximaler Fahrzeuganzahl: 0,58 % bei 200 und 1,62 % bei 250 Fahrzeugen. In Simulationen mit gestautem Verkehr wird eine marginale Energiebedarfssteigerung von 0,34 % festgestellt.
Beim Vergleich der durchschnittlichen Geschwindigkeiten in Szenarien mit freiem Verkehr, beispielsweise bei den Simulationen mit 200 Fahrzeugen, beeinflusst die zentralisierte Kolonnenregelung die Geschwindigkeiten aller Fahrzeuge nur marginal. Dies kann auf die niedrigere Verkehrsdichte zurückgeführt werden, die es den Fahrzeugen ermöglicht, unabhängig von der Geschwindigkeitsregelungsstrategie, ohne verkehrliche Stauungen auf den Routen operieren zu können. Daher bleibt der potenzielle Vorteil der zentralisierten Kolonnenregelung, den Verkehrsfluss zu optimieren, unausgeschöpft und dementsprechend in den Ergebnissen unrepräsentiert. Dennoch ist eine Erhöhung der durchschnittlichen Geschwindigkeit von 0,47 % durch die zentralisierte Geschwindigkeitsregelung festzustellen.
Bei den betrachteten Szenarien zeigt sich von gebundenem bis gestautem Verkehr, wie in den Simulationen mit 250 und 300 Fahrzeugen, ein Anstieg der durchschnittlichen Geschwindigkeiten um 1,91 % bzw. 2,94 %. Die verringerten Abstände zwischen den Fahrzeugen in einer Kolonne ermöglichen hier eine effizientere Auslastung des vorhandenen Straßenraums, wodurch die durchschnittliche Geschwindigkeit und der Verkehrsfluss insgesamt profitieren. Dies entspricht der Erwartung nach der mikroskopischen Auswertung, die bereits eine solche Tendenz bei erhöhtem Verkehrsaufkommen gezeigt hat.

7.2.2 Auswirkung auf den Verkehrsfluss

Abgesehen von der durchschnittlichen Geschwindigkeit wird die Auswirkung der zentralisierten Kolonnenregelung auf den Verkehrsfluss in diesem Abschnitt anhand der zuvor vorgestellten Fundamentaldiagramme dargestellt. In Abbildung 7.6 werden Fundamentaldiagramme von Verkehrssimulationen sowohl mit der Referenzstrategie (7.6a) als auch mit der zentralisierten Kolonnenregelung (7.6b) visualisiert.
Bei einer detaillierten Analyse der Verkehrsdichte und -stärke innerhalb der Simulationen unter Anwendung der Referenzstrategie zeigt sich, dass in den Szenarien mit maximal 200 Fahrzeugen der Großteil der Verkehrsdichte zwischen 29 und 55 Fahrzeugen pro Kilometer beträgt. Gleichzeitig liegt

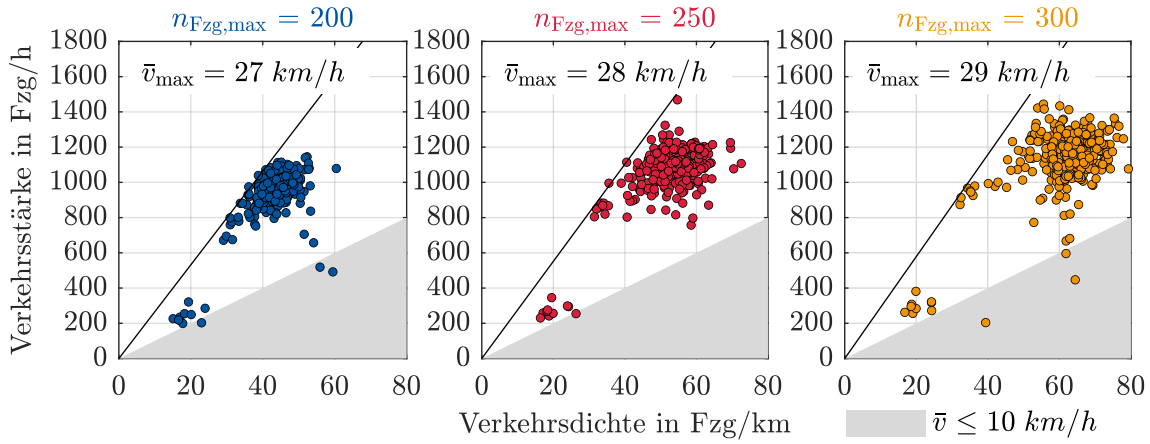

(a): Referenzstrategie

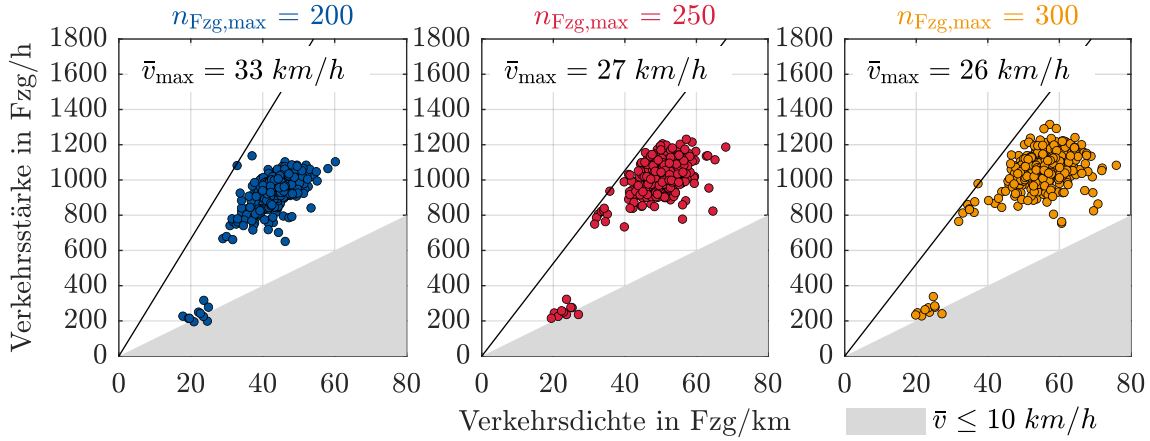

(b): Zentralisierte Kolonnenregelung

Abbildung 7.6: Darstellung der Verkehrssimulation mit unterschiedlicher Anzahl an Fahrzeugen und der beiden Strategien in Fundamentaldiagrammen

die Verkehrsstärke in einem Bereich von 655 bis 1143 Fahrzeugen pro Stunde. In den Szenarien, die unter Verwendung der zentralisierten Kolonnenregelung und derselben Fahrzeuganzahl durchgeführt wurden, verteilt sich der Großteil der Verkehrsdichte ebenfalls im Bereich von 29 bis 60 Fahrzeugen pro Kilometer. Die zugehörige Verkehrsstärke liegt dabei zwischen 658 und 1149 Fahrzeugen pro Stunde. Auffallend ist dabei die Beobachtung, dass bei vergleichbaren Werten der Verkehrsstärke die Simulationen, die auf der zentralisierten Kolonnenregelung basieren, eine erhöhte Verkehrsdichte aufzeigen. Dies korrespondiert zum einen mit den Ergebnissen bezüglich der durchschnittlichen Geschwindigkeiten und bestätigt zum anderen die vorherige Annahme, dass die implementierte Kolonnenregelung den Verkehrsfluss in Szenarien mit freiem Verkehr tendenziell negativ beeinflusst.
Beim Vergleich der Verkehrsdichte und -stärke in den Simulationen mit einer maximalen Fahrzeuganzahl von jeweils 250 und 300 unter Anwendung der Referenzstrategie als auch der zentralisierten Kolonnenregelung wird ersichtlich, dass die Werte in den Szenarien mit Referenzstrategie eine breitere Streuung aufweisen. Hierbei liegt die Verkehrsdichte bei 250 Fahrzeugen in einem Bereich zwischen 31 und 73 Fahrzeugen pro Kilometer, während diese bei 300 Fahrzeugen zwischen 32 und 79 Fahrzeugen pro Kilometer variiert. Demgegenüber liegen die entsprechenden Werte unter der zentralisierten Kolonnenregelung bei 250 Fahrzeugen zwischen 32 und 68 Fahrzeugen pro Kilometer und bei 300

Fahrzeugen zwischen 32 und 76 Fahrzeugen pro Kilometer.
Der Unterschied in der Verkehrsstärke ist noch ausgeprägter. Bei der Anwendung der Referenzstrategie variieren die Hauptanteile der Verkehrsstärke in den Simulationen mit 250 Fahrzeugen zwischen 748 und 1450 Fahrzeugen pro Stunde, während diese bei den Simulationen mit 300 Fahrzeugen zwischen 448 und 1447 Fahrzeugen pro Stunde liegen. In den gleichen Szenarien, die unter Verwendung der zentralisierten Kolonnenregelung durchgeführt wurden, befinden sich die Werte der Verkehrsstärke bei maximal 250 Fahrzeugen im Bereich zwischen 739 und 1240 Fahrzeugen pro Stunde und bei maximal 300 Fahrzeugen zwischen 750 und 1308 Fahrzeugen pro Stunde.
Die vorliegenden Daten mit der zentralisierten Kolonnenregelung signalisieren nicht nur eine Verbesserung in der durchschnittlichen Fahrgeschwindigkeit. Die breitere Streuung der Werte von den Verkehrskenngrößen bei Simulationen unter Verwendung der Referenzstrategie, ist ein Indikator für ein instabiles Verkehrsverhalten. Dies impliziert, dass es innerhalb der ausgewählten Fahrroute Straßenabschnitte gibt, in denen eine große Anzahl von Fahrzeugen sich mit verlangsamter Geschwindigkeit fortbewegt, während in anderen Straßenabschnitten Fahrzeuge aufgrund der geringeren Verkehrsdichte höhere Fahrgeschwindigkeiten erreichen können. Dadurch werden vermehrte Stop-and-Go Situationen und somit ein erhöhter gesamter Energiebedarf verursacht.
Der Einsatz der Referenzstrategie kann dazu führen, dass minimale Verkehrsstörungen, wie unerwartete Einscher-Manöver, aufgrund fehlender oder nicht vorausschauender Fahrzeuginteraktionen stockenden Verkehr verursachen. Diese Art der Verkehrsbehinderung, induziert durch geringfügige Störfaktoren, ist als Phantomstau bekannt und tritt mit zunehmendem Verkehrsaufkommen verstärkt in Erscheinung. Im Vergleich zur Referenzstrategie zeichnet sich die entwickelte zentralisierte Kolonnenregelung durch deren vorausschauende und optimierungsbasierte Geschwindigkeitsanpassung aus, die eine verbesserte Reaktion auf dynamische Verkehrsbedingungen ermöglicht. Ferner ermöglicht die zentralisierte Koordination von Fahrmanövern, unter Berücksichtigung der prädizierten Fahrtrajektorien benachbarter Verkehrsteilnehmer, eine frühzeitige Anpassung der eigenen Geschwindigkeit. Dies verhindert plötzliche Zustandsveränderungen des Fahrzeugs und trägt dazu bei, potenzielle Störquellen effektiv zu minimieren. In der Konsequenz führt dies zu einer Stabilisierung des Verkehrsflusses und einer Reduktion des gesamten Energiebedarfs.
Zusammenfassend kann festgestellt werden, dass die entwickelte zentralisierte Kolonnenregelung das Potenzial besitzt, den gesamten Energiebedarf der im Verkehrssystem teilnehmenden Fahrzeuge zu reduzieren. Insbesondere in Szenarien mit gebundenem und gestautem Verkehr erweist sich die Regelung als besonders effektiv, denn deren vorausschauende und optimierungsbasierte Regelungsmethodik trägt dazu bei, den allgemeinen Verkehrsfluss zu verbessern.

7.2.3 Einfluss von Parametern der Kolonnenregelung

Im abschließenden Abschnitt der Evaluation werden Untersuchungen vorgenommen, in denen die zwei wesentlichen Parameter der zentralisierten Kolonnenregelung, nämlich die Anzahl der Kolonnen und die Länge des Prädiktionshorizonts, variiert werden. Diese werden jeweils im Rahmen eines identischen Verkehrsszenarios simuliert. Das Ziel besteht darin, die systemischen Auswirkungen in Abhängigkeit der Parametervariationen eingehend zu charakterisieren und zu veranschaulichen.

Anzahl der Kolonnen

In den bisherigen präsentierten Evaluationen basieren die Ergebnisse auf Simulationen, die jeweils fünf Kolonnen mit einer Obergrenze von fünf Fahrzeugen pro Kolonne beinhalten. Im Rahmen der Simulationen, bei denen maximal 200 Fahrzeuge berücksichtigt wurden, wurde eine nachteilige Auswirkung der zentralisierten Kolonnenregelung auf den Verkehrsfluss festgestellt. Daher wird in diesem Szenario untersucht, ob eine Variation der Anzahl der Kolonnenfahrzeuge potenziell zu einer Verbesserung des Verkehrsflusses führt.
Unter Berücksichtigung einer Gesamtfahrzeuganzahl von maximal 200 in der Simulationsumgebung resultiert daraus eine maximale Durchdringungsrate der Kolonnenfahrzeuge von 12,5 %. Um die Auswirkungen einer variierenden Durchdringungsrate zu evaluieren, werden zusätzliche Simulationen mit 10, 15 und 20 Kolonnen bei gleichbleibender maximaler Gesamtfahrzeuganzahl von 200 durchgeführt. Daraus ergeben sich maximale Durchdringungsraten von 25 %, 37,5 % und 50 %. Analog zu den vorhergehenden Darstellungen visualisiert Abbildung 7.7 die Korrelation zwischen dem durchschnittlichen Energiebedarf und der durchschnittlichen Geschwindigkeit.

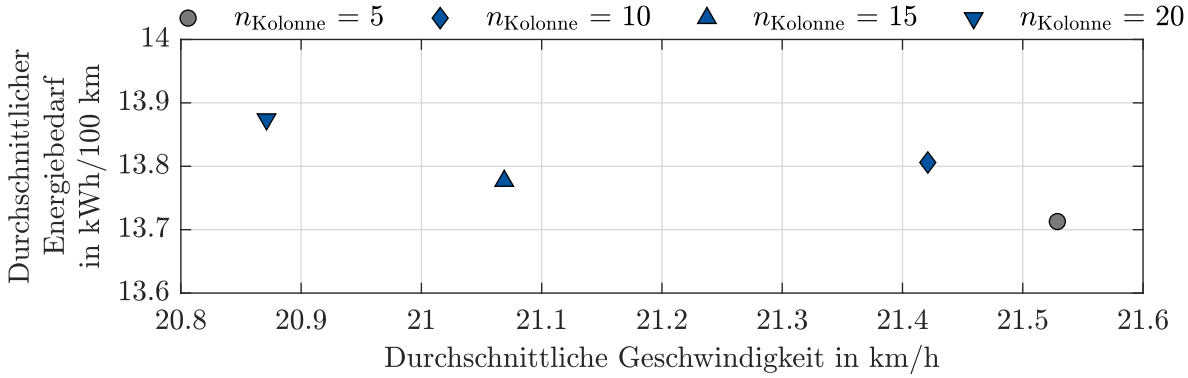

Abbildung 7.7: Darstellung des Energiebedarfs und der durchschnittlichen Geschwindigkeit aller Fahrzeuge bei $n_{\text{Fzg,max}} = 200$ und mit 5, 10, 15 und 20 Kolonnen

Es lässt sich feststellen, dass die durchschnittliche Geschwindigkeit über sämtliche Simulationen zwischen 21,07 und 21,52 km/h variiert, während der Energiebedarf in einem Intervall von 13,71 bis 13,87 kWh/100 km liegt. In dieser Betrachtung impliziert dies eine maximale Reduktion der durchschnittlichen Geschwindigkeit um bis zu 2 % und eine Zunahme des Energiebedarfs um bis zu 1,15 %. Daraus ergibt sich die Erkenntnis, dass unter Bedingungen eines freien Verkehrsflusses eine Erhöhung der Durchdringungsrate keine messbare Optimierung hinsichtlich der durchschnittlichen Geschwindigkeit und des Energiebedarfs mit sich bringt. Zur Visualisierung der Verkehrskenngrößen wird in Abbildung 7.8 die Verkehrsstärke in Relation zur Verkehrsdichte mittels des Fundamentaldiagramms dargestellt.
Bei einer Gegenüberstellung der Verkehrskenngrößen der Simulationen mit 10, 15 und 20 Kolonnen im Vergleich zu jenen mit lediglich 5 Kolonnen zeigt sich, dass der Großteil der ermittelten Werte in vergleichbaren Intervallen liegen. Die maximale durchschnittliche Geschwindigkeit auf der betrachteten Route beträgt bei Simulationen mit 10 und 15 Kolonnen 28 km/h und steigt bei 20 Kolonnen auf 37 km/h an. Dieser Wert wir jedoch als Ausreißer interpretiert, denn diese befinden sich außerhalb des überwiegenden Teils der generierten Ergebnisse. Diese Analyse unterstreicht, dass

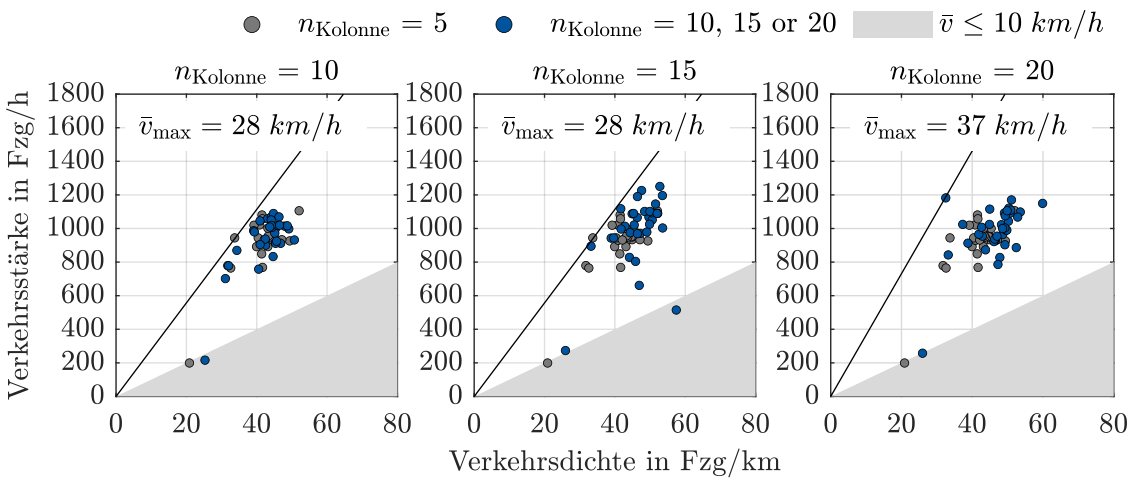

Abbildung 7.8: Darstellung der Verkehrssimulation mit unterschiedlicher Anzahl an Fahrzeugen mit zentralisierter Kolonnenregelung im Fundamentaldiagramm bei $n_{\text{Fzg,max}} = 200$ und mit 5, 10, 15 und 20 Kolonnen

selbst bei steigender Durchdringungsrate der Kolonnenfahrzeuge keine erhebliche Optimierung des Verkehrsflusses bei freiem Verkehr erzielt werden kann. Es verdeutlicht, dass unter bestimmten Verkehrsbedingungen die Durchdringungsrate kommunikationsfähiger Fahrzeuge und deren koordinierte Regelung nicht zwangsweise zu einer effizienteren Verkehrsdynamik führt.
Der Grund hierfür liegt in der Tatsache, dass jedes Fahrzeug bei freiem Verkehr ausreichend Verkehrsraum hat, um Fahrmanöver sicher durchzuführen, ohne dabei andere Verkehrsteilnehmer signifikant zu beeinträchtigen. Fahrzeuge, die das IDM-Fahrermodell verwenden, verfügen über genügend Zeit und Raum, um ihre Manöver sicher auszuführen.
Verschiedene Faktoren können die Effizienz der zentralisierten Kolonnenregelung beeinflussen. Dazu zählen Ungenauigkeiten in der Prädiktion sowie reduzierte Abstände zwischen den Fahrzeugen während der Durchführung von Fahrmanövern. Mit zunehmender Durchdringungsrate können diese Faktoren die Vorteile der Kolonnenregelung teilweise oder sogar vollständig neutralisieren.

Prädiktionshorizont

Basierend auf den Erkenntnissen aus Kapitel 6.2.5 lässt sich feststellen, dass durch eine gezielte Erhöhung des Prädiktionshorizonts das Potenzial besteht, den Energiebedarf effizient zu reduzieren. Infolgedessen werden Simulationen unter Berücksichtigung unterschiedlicher Verkehrsdichten durchgeführt, wobei stets fünf Kolonnen betrachtet werden und der Prädiktionshorizont N_{p} auf 30 s erweitert wird. Die Korrelation zwischen dem durchschnittlichen Energiebedarf und der durchschnittlichen Geschwindigkeit wird in Abbildung 7.9 visualisiert.
In der grafischen Darstellung werden die Ergebnisse mit einem Prädiktionshorizont $N_{\text{p}} = 15$ s mittels gefüllter Kreissymbole und jene mit einem $N_{\text{p}} = 30$ s durch gefüllte Rautensymbole repräsentiert. Bei einer gegenüberstellenden Betrachtung der Daten mit einem $N_{\text{p}} = 15$ s ist eine Änderung in der durchschnittlichen Geschwindigkeit um 0,13 %, 0,92 % und -0,52 % bei $n_{\text{Fzg,max}}$ von 200, 250 bzw. 300 zu verzeichnen. Hinsichtlich des durchschnittlichen Energiebedarfs zeigt sich jeweils eine Veränderung von 0,17 %, 0,77 % und 0,74 %.

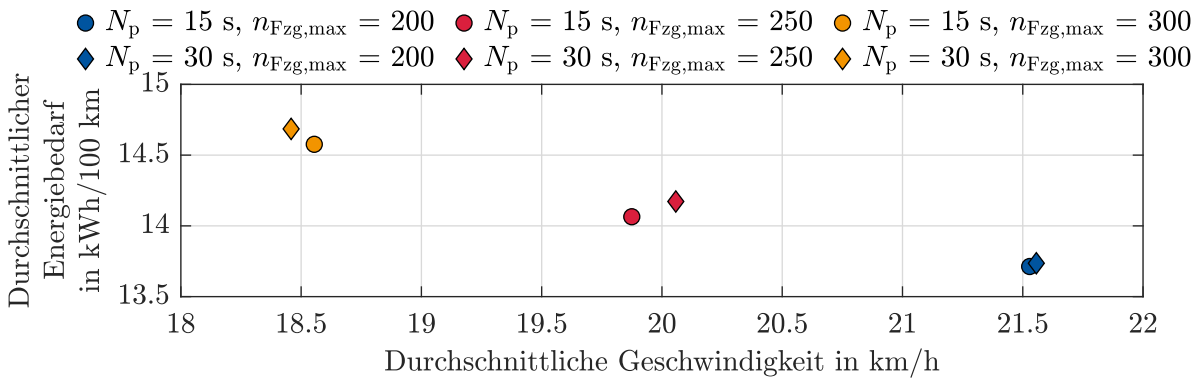

Abbildung 7.9: Darstellung des Energiebedarfs und der durchschnittlichen Geschwindigkeit aller Fahrzeuge bei $n_{Fzg,max}$ = 200, 250 und 300 sowie mit N_p = 15 und 30 s

Die marginalen Unterschiede in den Ergebnissen unterstreichen, dass eine Erhöhung des Prädiktionshorizonts nicht zwangsläufig zu einer signifikanten Optimierung des gesamten Energiebedarfs oder der durchschnittlichen Geschwindigkeit führt. Ein möglicher Erklärungsansatz hierfür sind die dynamisch wechselnden Verkehrsbedingungen, wodurch die im Abschnitt 5 vorgestellten Prädiktionsmodelle bei längeren Prädiktionshorizonten tendenziell erhöhte Abweichungen aufweisen. Dies wirkt sich auf die Lösung des Optimierungsproblems für die Kolonnenregelung aus. Bei einem höheren Prädiktionshorizont sinkt die Genauigkeit der geplanten Trajektorien der Kolonnenfahrzeuge. Demzufolge impliziert ein größerer Prädiktionshorizont nicht unbedingt eine bessere Optimierungsleistung. Die oben genannten Erkenntnisse werden durch die in Abbildung 7.10 dargestellten Daten veranschaulicht.

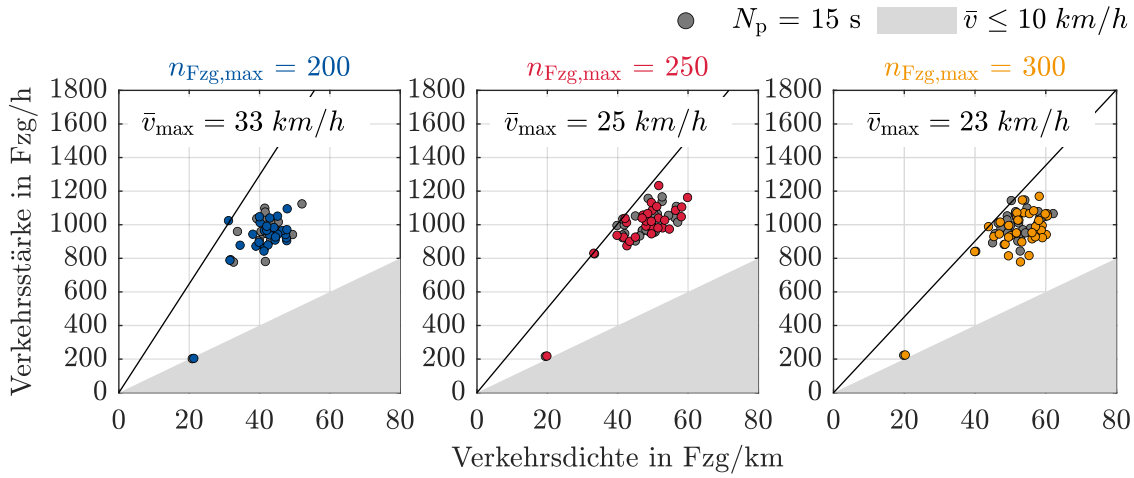

Abbildung 7.10: Darstellung der Verkehrssimulation mit unterschiedlicher Anzahl an Fahrzeugen mit zentralisierter Kolonnenregelung im Fundamentaldiagramm mit N_p = 15 und 30 s

Bei einer Analyse der Verkehrskenngrößen unter Berücksichtigung unterschiedlicher Verkehrsaufkommen und Prädiktionshorizonte zeigt sich keine merkliche Abweichung der ermittelten Daten. Sowohl die Verkehrsdichte als auch die Verkehrsstärke liegen innerhalb vergleichbarer Intervallbereiche. Diese Beobachtung lässt den Schluss zu, dass eine Erhöhung des Prädiktionshorizonts von 15 s auf 30 s nicht zu einer merklichen Steigerung der Verkehrsflussstabilität führt. Allerdings steigt mit einer Erhöhung des Prädiktionshorizonts die Komplexität des Optimierungsproblems exponentiell an. Dies führt zu einer erheblichen Zunahme der Rechenzeit des Algorithmus, was einen signifikanten

Nachteil der Erweiterung des Prädiktionshorizonts darstellt.

7.3 Diskussion der Ergebnisse

In der vorliegenden Arbeit wurde eine prädiktive und kooperative Fahrfunktion untersucht, wobei insbesondere die zentralisierte kooperative Fahrzeugführung sowie ein ganzheitliches Fahrmanövermanagement in den Fokus gerückt wurden. In einem spezifisch ausgewählten Folgefahrtszenario konnte, bei Anwendung der zentralisierten kooperativen Fahrzeugführung mit definierten Parametereinstellungen und einem Prädiktionshorizont von 15 Sekunden, ein Energieeinsparungspotenzial von 11,10 % identifiziert werden. Dies deutet darauf hin, dass durch die Minimierung unnötiger Beschleunigungs- und Verzögerungsmanöver aller Kolonnenfahrzeuge der Gesamtenergiebedarf reduziert werden kann.
Das entwickelte ganzheitliche Fahrmanövermanagement ermöglicht eine effiziente Untersuchung verschiedener typischer urbaner Fahrmanöver, wie beispielsweise das Aufschließ-, Einscher-, Ausscher- sowie Aufteilungsmanöver, die durch LSA oder NAF bedingt sind. Die Simulationsergebnisse verdeutlichen, dass mittels der Prädiktion der Fahrtrajektorien von umgebenden Verkehrsteilnehmern und einer optimierungsbasierten Geschwindigkeitsanpassung aller am Manöver beteiligten Fahrzeuge, ein solches Fahrmanöver frühzeitig und energetisch optimiert durchgeführt werden kann. Somit werden weitere Verkehrsteilnehmer nur minimal von dem Fahrmanöver beeinflusst.
Mittels der in Abbildung 3.1 dargestellten Co-Simulationsplattform besteht die Möglichkeit, prädiktive kooperative Fahrfunktion systematisch in einer realitätsnahen Verkehrssimulationsumgebung zu evaluieren. Aus der detaillierten Analyse des Fahrverhaltens geht hervor, dass die Fahrzeuge der Kolonne im Gegensatz zur herangezogenen Referenzstrategie in der Lage sind, die eigene Geschwindigkeit bei Veränderung der Fahrzeugzustände benachbarter Verkehrsteilnehmer frühzeitig anzupassen. Die FF neigen dazu, dem VF mit kleinem Abstand und einer niedrigeren relativen Geschwindigkeit zu folgen. Ein Vorteil des zentralisierten Ansatzes besteht in der ganzheitlichen Betrachtung der Fahrzeugzustände aller Kolonnenfahrzeuge. Dies ermöglicht die Berücksichtigung des Zustands des jeweiligen VFs eines FFs in der Optimierung. Dadurch kann der Abstand zwischen den FF minimiert werden, ohne das allgemeine Fahrverhalten nachteilig zu beeinflussen.
Eine detaillierte Analyse des Energiebedarfs quantifiziert, wie der Energiebedarf in freiem, gebundenem oder gestautem Verkehr beeinflusst wird. In Simulationen mit einer Fahrzeuganzahl von jeweils 200, 250 und 300 Fahrzeugen erreicht das Energieeinsparpotenzial aller Kolonnenfahrzeuge die Werte von 2,92 %, 9,14 % bzw. 7,89 %. Analog dazu zeigt sich, dass bei einer Gesamtbetrachtung sämtlicher in der Simulation vorhandenen Fahrzeuge der Energiebedarf ebenfalls beeinflusst werden kann. In Simulationen mit einer Anzahl von 200 und 250 Fahrzeugen liegt das Energieeinsparpotenzial bei 0,58 % und 1,62 %. Eine marginale Energiebedarfserhöhung von 0,34 % wird in Simulationen mit 300 Fahrzeugen festgestellt.
Bei der Analyse der Verkehrskenngrößen lässt sich erkennen, dass die zentralisierte Kolonnenregelung in Szenarien eines freien Verkehrs nur geringfügige Auswirkungen auf den Verkehrsfluss zeigt. In Szenarien mit gebundenem und gestautem Verkehr hat die zentralisierte Kolonnenregelung einen po-

sitiven Einfluss auf den Verkehrsfluss. Dabei wird nicht ausschließlich die durchschnittliche Geschwindigkeit gesteigert, sondern insgesamt ein stabilerer Verkehrsfluss realisiert, wodurch Verkehrsstaus infolge unvorhergesehener Fahrmanöver reduziert werden können.
Bei der Erzielung dieser Ergebnisse sind bestimmte Einschränkungen zu berücksichtigen. Die Fahrzeugkommunikation innerhalb der Simulation wird als idealisiert betrachtet, wodurch potenzielle Einflüsse wie Abschattungseffekte, externe Störgrößen und Datenverluste nicht berücksichtigt werden. Es wurde angenommen, dass 85 % aller Verkehrsteilnehmer kommunikationsfähige Fahrzeuge sind. Obwohl das IDM-Fahrermodell für die umgebenden Verkehrsteilnehmer variabel parametriert wurde, basiert die Berechnung der Beschleunigung letztlich auf identischen Gleichungen, was zu homogenen Fahrverhalten führt. Darüber hinaus stützt sich die Analyse des Energieeinsparpotenzials ausschließlich auf batterieelektrische Fahrzeuge, was nicht der realen Verkehrskonstellation entspricht.
Abseits der Simulationsumgebung wurden auch in der Ausarbeitung des Prädiktionsmodells Vereinfachungen vorgenommen. Die zum Trainieren des Modells verwendeten Daten stammen direkt aus der Simulationsumgebung, weshalb hauptsächlich Verhaltensweisen des IDM sowie des Fahrstreifenwechselmodells adaptiert wurden. Eine Generierung von Daten zur Prädiktion des Fahrstreifenwechsels im realen Verkehr ist unter aktuellen Bedingungen nicht umsetzbar, da hierfür spezifische Eingangsdaten erforderlich sind, die ohne zusätzliche Sensortechnik im Fahrzeug nicht erfasst werden können. Dennoch wurde während der Vorbereitungsphase ein Prädiktionsmodell für das VF eingesetzt, das auf realistischen Messdaten basiert. Hierdurch konnte eine vergleichbare Genauigkeit in der Fahrtrajektorienprädiktion erzielt werden. Daher kann angenommen werden, dass das mit dem SUMO-Fahrzeugmodell trainierte Prädiktionsmodell eine hinreichende Genauigkeit aufweist.
Eine letzte Einschränkung in der Generierung der Ergebnisse ergibt sich aus den MPR-Algorithmus selbst. Während der Simulationsphasen wurde beobachtet, dass das zugrundeliegende Optimierungsproblem insbesondere in Stillstandsphasen, in denen die Geschwindigkeit der Kolonnenfahrzeuge unter 1 km/h abfällt, nicht lösbar erscheint. In diesen Situationen stellt sich der Lösungsraum in Bezug auf den Abstand aller Kolonnenfahrzeuge als besonders eingeschränkt dar. Oftmals liegt die Differenz der maximalen und minimalen Abstandsgrenzen in einem Bereich von einem bis zwei Metern. In Kombination mit Abweichungen in der Trajektorienprädiktion führt dies zu einem unlösbaren Optimierungsproblem. Um während solcher Phasen eine kontinuierliche Fahrzeugführung zu gewährleisten, wird der Solver des MPR zurückgesetzt und temporär das IDM-Fahrermodell für sämtliche Kolonnenfahrzeuge aktiviert. Sobald das Optimierungsproblem wieder lösbar ist, wird die zentralisierte Kolonnenregelung reaktiviert.
Ein weiterer bedeutsamer Aspekt ist die Rechenzeit des verwendeten Algorithmus. Die durchschnittliche Ausführungszeit des Algorithmus beträgt das Zehnfache der simulierten Zeit. Bei Integration der zentralisierten Kolonnenregelung in ein leistungsstarkes Prototypensteuergerät zeigte sich, dass lediglich bei Anwendung mit einem einzigen FF und einem Prädiktionshorizont von 8 Sekunden keine Überschreitung des Task-Intervalls auftritt. Daher erweist sich eine weitere Optimierung des Programmcodes als unerlässlich, bevor weiterführende Fahrzeugtests durchgeführt werden können.

8 Zusammenfassung und Ausblick

Die vorliegende Forschungsarbeit verfolgte das Ziel, eine prädiktive kooperative Fahrfunktion zu entwickeln, die sowohl die optimierungsbasierte Fahrzeugführung als auch das ganzheitliche Fahrmanövermanagement beinhaltet. Des Weiteren zielte diese Dissertationsschrift darauf ab, die entwickelte Fahrfunktion systematisch innerhalb realitätsnaher Verkehrssimulationen hinsichtlich des Potenzials zur Energieeinsparung und Verbesserung des Verkehrsflusses zu evaluieren. Drei zentrale Forschungsfragen wurden zu Beginn der Dissertationsschrift formuliert. Die daraus abgeleiteten Erkenntnisse können wie folgt zusammengefasst werden.

Um die Untersuchung prädiktiver kooperativer Fahrfunktion durchzuführen, wurde im Kapitel 4 eine realistische Simulationsumgebung bereitgestellt, welche den inneren Ring der Paderborner Innenstadt hinsichtlich Routenführung, Schaltprogrammen und Verkehrsaufkommen realitätsnah nachbildet. Weiterhin wurde eine Parametrierung des Fahrzeugfolgemodells IDM mithilfe realistischer Messdaten durchgeführt. Nach einer eingehenden Verifizierung dieser Simulationsumgebung konnte festgestellt werden, dass die modellierten Verkehrsszenarien sowohl in Bezug auf Verkehrsdynamik, Fahrverhalten als auch Energiebedarf ausreichend realitätsnahe Verkehrsgeschehen unter verschiedenen Verkehrsaufkommen widerspiegeln konnten.

Zur frühzeitigen Erkennung der Intentionen umliegender Verkehrsteilnehmer wurden in Kapitel 5 zwei Ansätze mittels der LSTM-Netzwerken entwickelt, welche darauf abzielten, sowohl die longitudinale Geschwindigkeit des VFs als auch die longitudinale und laterale Geschwindigkeit benachbarter Fahrzeuge während des Fahrstreifenwechsels vorherzusagen. Zur Bewertung der Modellgenauigkeit wurde die prädizierte Geschwindigkeit innerhalb der Simulationsumgebung mit dem tatsächlichen Geschwindigkeitsverlauf des VFs und benachbarter Fahrzeuge verglichen. Die erzielten Ergebnisse zeigen, dass die Medianabweichungen des VFs in Bezug auf Geschwindigkeit und Abstand über den Prädiktionshorizont hinweg zu vernachlässigen sind. Bei der Prädiktion des Fahrstreifenwechsels betragen die maximalen Abweichungen -4,6 km/h und -12,1 m. Eine Tendenz zu negativen Abweichungen ist zu beobachten, was darauf hinweist, dass das entwickelte Modell tendenziell zu einer Prädiktion höherer Geschwindigkeit für benachbarte Fahrzeuge neigt. Die Prädiktionsabweichungen bei VF zeigen bis zu einem Prädiktionshorizont von 11 Sekunden eine Zunahme und stabilisieren sich anschließend. Der Interquartilsabstand bei maximaler Abweichung variiert zwischen -3,4 und 3,6 km/h. Bei der Prädiktion hinsichtlich des Fahrstreifenwechsels steigen die Prädiktionsabweichungen bis zu einem Prädiktionshorizont von neun Sekunden, wobei eine abnehmende Tendenz bis zur 15 s erkennbar ist. Der maximale Interquartilsabstand liegt zwischen 13,4 km/h und -21,0 km/h.

In Kapitel 6 wurde die prädiktive und kooperative Fahrfunktion entwickelt. Dabei wurde ein zentralisierter Ansatz sowohl für die optimierungsbasierte Fahrzeugführung als auch für das Fahrmanövermanagement konzipiert, in dem sowohl die Fahrzeugzustände von Kolonnenführern als auch von allen Folgefahrzeugen gemeinsam in einem auf einem MPR-Algorithmus basierten Optimierungsproblem betrachtet wurden. Durch die Gewichtungen in den dazu aufgestellten Kostenfunktion können unnötige Beschleunigungs- und Verzögerungsvorgänge minimiert und somit der Energiebedarf

im ausgewähltem Folgefahrtszenario um 11,10 % reduziert werden. Durch die Integration der Fahrtrajektorienprädiktion benachbarter Fahrzeuge und die ganzheitliche Koordination unterschiedlicher Fahrmanöver kann die Geschwindigkeit aller Kolonnenfahrzeuge energetisch optimiert angepasst und die Fahrmanöver effizienter durchgeführt werden, wodurch Beeinträchtigungen anderer Verkehrsteilnehmer reduziert werden. Nach der Zusammenführung der Fahralgorithmen und der Integration in die Simulationsumgebung wurden umfangreiche Simulationen mit unterschiedlichen Verkehrsszenarien und -aufkommen durchgeführt.

Im abschließenden Kapitel 7 wurde eine umfassende mikro- und makroskopische Bewertung der entwickelten prädiktiven kooperativen Fahrfunktion durchgeführt. Mikroskopisch wurde das Fahrverhalten und der Energiebedarf der Kolonnenfahrzeuge in verschiedenen Verkehrssituationen evaluiert. Mithilfe der Prädiktionsmodelle des VFs und der benachbarten Verkehrsteilnehmer, gekoppelt mit dem Informationsaustausch zwischen Fahrzeugen und Infrastruktur durch V2V- und V2I-Kommunikation, kann die entwickelte Fahrfunktion die Geschwindigkeitsanpassungen frühzeitig und energetisch optimiert vornehmen. Die FF folgen dem jeweiligen VF mit reduziertem Abstand und niedrigerer relativer Geschwindigkeit, das zu einer höheren Verkehrsdichte bei gleichbleibenden Geschwindigkeiten und somit zu einer effektiveren Ausnutzung der Straßenkapazität führt.

Bei der energetischen Analyse zeigt sich ein Energieeinsparpotenzial aller Kolonnenfahrzeuge von 2,92 %, 9,14 % und 7,89 % für Simulationsszenarien von 200, 250 bzw. 300 Fahrzeugen. Es wird festgestellt, dass das Energieeinsparpotenzial mit steigender Fahrzeugposition in einer Kolonne abnimmt. Bei freien Verkehrsbedingungen, wie in den Simulationen mit 200 Fahrzeugen, wird eine Energiebedarfssteigerung von 10,9 % bei FF4 beobachtet. Die Auswertungen zur durchschnittlichen Geschwindigkeit der Kolonnenfahrzeuge zeigen eine Geschwindigkeitsreduktion von 8,68 % in Simulationen mit 200 Fahrzeugen. Im Gegensatz dazu kann in Simulationen mit 250 bzw. 300 Fahrzeugen eine Steigerung der durchschnittlichen Geschwindigkeit von bis zu 3,66 % bzw. 12,06 % beobachtet werden. Die Ursache liegt im großen Abstand zwischen den Fahrzeugen im freien Verkehr. Bei Anwendung der zentralisierten Kolonnenregelung werden die Abstände zwischen den Fahrzeugen tendenziell geringer als in der Referenzstrategie gehalten. Bei Einscher- und Aufteilungsmanöver wird der Abstand durch Verzögerung einiger Kolonnenfahrzeuge vergrößert, was nachteilige Auswirkungen auf den Energiebedarf hat. Im Gegensatz dazu ermöglicht die ganzheitliche Koordination der Fahrmanöver in Szenarien des gebundenen und gestauten Verkehrs eine effizientere Durchführung der Fahrmanöver bei erhöhter Verkehrsdichte. Dies steigert das Energieeinsparpotenzial und fördert einen verbesserten Verkehrsfluss.

Makroskopisch sind Energieeinsparungen für die Gesamtverkehrssituation unter verschiedenen Verkehrssituationen sichtbar. Simulationen mit 200 und 250 Fahrzeugen zeigen Energieeinsparpotenziale von 0,58 % und 1,62 %. Im Gegensatz dazu zeigt die Simulation mit maximal 300 Fahrzeugen eine marginale Erhöhung des Energiebedarfs um 0,34 %. Gleichzeitig lässt sich eine Zunahme der durchschnittlichen Geschwindigkeiten in den Simulationen mit 200, 250 und 300 Fahrzeugen beobachten, das einer Steigerung von 0,47 %, 1,91 % und 2,94 % entspricht. Durch den Vergleich der Verkehrskenngrößen mittels Fundamentaldiagrammen können Erkenntnisse bezüglich des ganzheitlichen Fahrmanövermanagements extrahiert werden. Insbesondere wird deutlich, dass die vorausschauen-

de und optimierungsbasierte Geschwindigkeitsanpassung eine effektive Strategie zur Reaktion auf dynamische Verkehrsbedingungen darstellt. Dieses Modell vermeidet plötzliche Veränderungen im Fahrzeugzustand und minimiert potenzielle Störungen. Dies resultiert in einer Verkehrsflussstabilisierung und einer signifikanten Minderung des Gesamtenergiebedarfs.

Als Ausblick gilt es in künftigen Forschungsarbeiten detailliert zu untersuchen, wie Abschattungseffekte, externe Störungen und Kommunikationsdatenverluste die Wirksamkeit prädiktiver und kooperativer Fahrfunktionen beeinflussen. Ein erster Schritt wäre die Integration einer simulierten V2V- und V2I-Kommunikation mit realistischen Verzugs- und Verlustquoten, gefolgt von einer Erweiterung der prädiktiven kooperativen Fahrfunktion, bevor diese in realen Fahrzeugen implementiert wird. Als nächstes sollte untersucht werden, inwiefern der Anteil der kommunikationsfähigen Fahrzeuge das Energieeinsparpotenzial und den Verkehrsfluss beeinflussen werden. Ein Vergleich des zentralisierten Ansatzes mit einem verteilten, jedoch optimierungsbasierten Ansatz wäre zudem von Bedeutung, insbesondere weil festgestellt wurde, dass ein zentralisierter Ansatz den Verkehrsfluss unter freien Bedingungen negativ beeinflusst. Es gilt alternative Strategien für solche Verkehrsbedingungen zu entwickeln.

Neben den simulativen Untersuchungen wäre ein nächster Schritt die Implementierung und Evaluierung der entwickelten prädiktiven kooperativen Fahrfunktion in realen Testumgebungen. Hierbei soll zunächst die Echtzeitfähigkeit der Fahrfunktion abhängig von der Anzahl der beteiligten Fahrzeuge und variierenden Parametereinstellungen evaluiert werden. Durch die Implementierung der Fahrfunktion in ein hochleistungsfähiges Prototypensteuergerät lässt sich eine realistische Ausführungszeit bestimmen. Nach der Anpassung der Fahrfunktion wäre es zielführend, diese in einem realen Fahrzeugs, gekoppelt mit simulierter Verkehrsumgebung (Vehicle-in-the-Loop, ViL), zu untersuchen. Des Weiteren könnte die Fahrfunktion in Bezug auf die Programmierlogik optimiert werden, mit dem Ziel, diese in mehreren Fahrzeugen mit einer optimalen Parametereinstellung zu integrieren, ohne die Echtzeitfähigkeit zu verletzen. Fortführend könnten weitere Fahrzeugversuche mit mehreren realen Fahrzeuge in einer ViL-Umgebung durchgeführt werden. Dies erlaubt der Fahrzeugkolonne in einer realitätsnahen Verkehrsumgebung mit weiteren Verkehrsteilnehmern zu agieren und realistische Fahrmanöver abzubilden. Die im Rahmen dieser Versuche generierten Daten stellen eine essenzielle Datenbasis für die Beurteilung prädiktiver kooperativer Fahrfunktion und die ganzheitliche Bewertung des Verkehrsgeschehens dar.

Literaturverzeichnis

[1] M. Wegener, F. Herrmann, L. Koch, R. Savelsberg und J. Andert, "Longitudinal Vehicle Motion Prediction in Urban Settings with Traffic Light Interaction," *IEEE Transactions on Intelligent Vehicles*, S. 1–1, 2021. DOI: 10.1109/TIV.2021.3114156.

[2] M. Eisenbarth, "Prädiktion von Verkehrsrandbedingungen zur Effizienzsteigerung vernetzter und automatisierter Fahrzeuge," Veröffentlicht auf dem Publikationsserver der RWTH Aachen University; Dissertation, Rheinisch-Westfälische Technische Hochschule Aachen, 2023, Dissertation, Rheinisch-Westfälische Technische Hochschule Aachen, Aachen, 2023, 1 Online–Ressource : Illustrationen, Diagramme. DOI: 10.18154/RWTH-2023-04527. Adresse: https://publications.rwth-aachen.de/record/957047.

[3] J. Göbel, *Radartechnik: Grundlagen und Anwendungen*. VDE-Verlag, 2011, ISBN: 9783800731411. Adresse: https://books.google.de/books?id=QaMbPwAACAAJ.

[4] J. Kernhof, J. Leuckfeld und G. Tavano, "LiDAR-Sensorsystem für automatisiertes und autonomes Fahren," in *Automobil-Sensorik 2: Systeme, Technologien und Applikationen*, T. Tille, Hrsg. Berlin, Heidelberg: Springer Berlin Heidelberg, 2018, S. 29–54, ISBN: 978-3-662-56310-6. DOI: 10.1007/978-3-662-56310-6_2.

[5] K. Reif, "Sensoren im Kraftfahrzeug," in *Sensoren im Kraftfahrzeug*, K. Reif, Hrsg. Wiesbaden: Vieweg+Teubner Verlag, 2012, S. 10–33, ISBN: 978-3-8348-2208-6. DOI: 10.1007/978-3-8348-2208-6_1.

[6] L. F. Pau, "Sensor data fusion," 1988, ISSN: 1573-0409. DOI: 10.1007/BF00348718. Adresse: https://doi.org/10.1007/BF00348718.

[7] J. Llinas und D. Hall, "An introduction to multi-sensor data fusion," in *ISCAS '98. Proceedings of the 1998 IEEE International Symposium on Circuits and Systems (Cat. No.98CH36187)*, Bd. 6, 1998, 537–540 vol.6. DOI: 10.1109/ISCAS.1998.705329.

[8] J. Bleiholder und F. Naumann, "Data Fusion," *ACM Comput. Surv.*, Jg. 41, Nr. 1, 2009, ISSN: 0360-0300. DOI: 10.1145/1456650.1456651. Adresse: https://doi.org/10.1145/1456650.1456651.

[9] H. Durrant-Whyte und T. C. Henderson, "Multisensor Data Fusion," in *Springer Handbook of Robotics*, B. Siciliano und O. Khatib, Hrsg. Cham: Springer International Publishing, 2016, S. 867–896, ISBN: 978-3-319-32552-1. DOI: 10.1007/978-3-319-32552-1_35. Adresse: https://doi.org/10.1007/978-3-319-32552-1_35.

[10] M. Atluri, M. Chowdhury, N. Kanhere, R. Fries, W. Sarasua und J. Ogle, "Development of a sensor system for traffic data collection," *Journal of Advanced Transportation*, Jg. 43, Nr. 1, S. 1–20, 2009. DOI: https://doi.org/10.1002/atr.5670430102.

[11] J. Van Brummelen, M. O' Brien, D. Gruyer und H. Najjaran, "Autonomous vehicle perception: The technology of today and tomorrow," *Transportation Research Part C: Emerging Technologies*, Jg. 89, S. 384–406, 2018, ISSN: 0968-090X. DOI: https://doi.org/10.1016/j.trc.2018.02.012. Adresse: https://www.sciencedirect.com/science/article/pii/S0968090X18302134.

[12] A. Petrovskaya und S. Thrun, "Model based vehicle detection and tracking for autonomous urban driving," *Autonomous Robots*, Jg. 26, 2009, ISSN: 1573-7527. DOI: 10.1007/s10514-009-9115-1. Adresse: https://doi.org/10.1007/s10514-009-9115-1.

[13] L. Zheng, B. Li, H. Zhang, Y. Shan und J. Zhou, "A High-Definition Road-Network Model for Self-Driving Vehicles," *ISPRS International Journal of Geo-Information*, Jg. 7, Nr. 11, 2018, ISSN: 2220-9964. DOI: 10.3390/ijgi7110417. Adresse: https://www.mdpi.com/2220-9964/7/11/417.

[14] R. Liu, J. Wang und B. Zhang, "High Definition Map for Automated Driving: Overview and Analysis," *Journal of Navigation*, Jg. 73, S. 1–18, Aug. 2019. DOI: 10.1017/S0373463319000638.

[15] V. Ilci und C. Toth, "High Definition 3D Map Creation Using GNSS/IMU/LiDAR Sensor Integration to Support Autonomous Vehicle Navigation," *Sensors*, Jg. 20, Nr. 3, 2020, ISSN: 1424-8220. DOI: 10.3390/s20030899. Adresse: https://www.mdpi.com/1424-8220/20/3/899.

[16] B. Ebrahimi Soorchaei, M. Razzaghpour, R. Valiente, A. Raftari und Y. P. Fallah, "High-Definition Map Representation Techniques for Automated Vehicles," *Electronics*, Jg. 11, Nr. 20, 2022, ISSN: 2079-9292. DOI: 10.3390/electronics11203374. Adresse: https://www.mdpi.com/2079-9292/11/20/3374.

[17] Z. Bao, S. Hossain, H. Lang und X. Lin, "A review of high-definition map creation methods for autonomous driving," *Engineering Applications of Artificial Intelligence*, Jg. 122, S. 106 125, 2023, ISSN: 0952-1976. DOI: https://doi.org/10.1016/j.engappai.2023.106125. Adresse: https://www.sciencedirect.com/science/article/pii/S0952197623003093.

[18] C. Sommer und F. Dressler, *Vehicular Networking*. Cambridge University Press, ISBN: 978-1-107-04671-9. DOI: 10.1017/CBO9781107110649.

[19] V. Mannoni, V. Berg, S. Sesia und E. Perraud, "A Comparison of the V2X Communication Systems: ITS-G5 and C-V2X," in *2019 IEEE 89th Vehicular Technology Conference (VTC2019-Spring)*, 2019, S. 1–5. DOI: 10.1109/VTCSpring.2019.8746562.

[20] M. H. C. Garcia u. a., "A Tutorial on 5G NR V2X Communications," *IEEE Communications Surveys and Tutorials*, Jg. 23, Nr. 3, S. 1972–2026, 2021. DOI: 10.1109/COMST.2021.3057017.

[21] M. Fallgran u. a., "On Selected V2X Technology Components and Enablers from the 5GCAR Project," in *2018 IEEE International Symposium on Broadband Multimedia Systems and Broadcasting (BMSB)*, 2018, S. 1–5. DOI: 10.1109/BMSB.2018.8436731.

[22] R. Jacob, N. Franchi und G. Fettweis, "Hybrid V2X Communications: Multi-RAT as Enabler for Connected Autonomous Driving," in *2018 IEEE 29th Annual International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC)*, 2018, S. 1370–1376. DOI: 10.1109/PIMRC.2018.8580953.

[23] S. Fu, W. Zhang und Z. Jiang, "A network-level connected autonomous driving evaluation platform implementing C-V2X technology," *China Communications*, Jg. 18, Nr. 6, S. 77–88, 2021. DOI: 10.23919/JCC.2021.06.007.

[24] H. Bagheri u. a., "5G NR-V2X: Toward Connected and Cooperative Autonomous Driving," *IEEE Communications Standards Magazine*, Jg. 5, Nr. 1, S. 48–54, 2021. DOI: 10.1109/MCOMSTD.001.2000069.

[25] T. Streubel und K. H. Hoffmann, "Prediction of driver intended path at intersections," in *2014 IEEE Intelligent Vehicles Symposium Proceedings*, 2014, S. 134–139. DOI: 10.1109/IVS.2014.6856508.

[26] A. Carvalho, Y. Gao, S. Lefèvre und F. Borrelli, "Stochastic Predictive Control of Autonomous Vehicles in Uncertain Environments," 2014. Adresse: https://api.semanticscholar.org/CorpusID:14171346.

[27] S. Yoon und D. Kum, "The multilayer perceptron approach to lateral motion prediction of surrounding vehicles for autonomous vehicles," in *2016 IEEE Intelligent Vehicles Symposium (IV)*, 2016, S. 1307–1312. DOI: 10.1109/IVS.2016.7535559.

[28] A. Khosroshahi, E. Ohn-Bar und M. M. Trivedi, "Surround vehicles trajectory analysis with recurrent neural networks," in *2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)*, 2016, S. 2267–2272. DOI: 10.1109/ITSC.2016.7795922.

[29] D. J. Phillips, T. A. Wheeler und M. J. Kochenderfer, "Generalizable intention prediction of human drivers at intersections," in *2017 IEEE Intelligent Vehicles Symposium (IV)*, 2017, S. 1665–1670. DOI: 10.1109/IVS.2017.7995948.

[30] D. Moser, R. Schmied, H. Waschl und L. del Re, "Flexible Spacing Adaptive Cruise Control Using Stochastic Model Predictive Control," *IEEE Transactions on Control Systems Technology*, Jg. 26, Nr. 1, S. 114–127, 2018. DOI: 10.1109/TCST.2017.2658193.

[31] F. Altché und A. de La Fortelle, "An LSTM Network for Highway Trajectory Prediction," *CoRR*, Jg. abs/1801.07962, 2018. arXiv: 1801.07962. Adresse: http://arxiv.org/abs/1801.07962.

[32] K. Messaoud, I. Yahiaoui, A. Verroust-Blondet und F. Nashashibi, "Non-local Social Pooling for Vehicle Trajectory Prediction," in *2019 IEEE Intelligent Vehicles Symposium (IV)*, 2019, S. 975–980. DOI: 10.1109/IVS.2019.8813829.

[33] A. Benterki, V. Judalet, M. Choubeila und M. Boukhnifer, "Long-Term Prediction of Vehicle Trajectory Using Recurrent Neural Networks," in *IECON 2019 - 45th Annual Conference of the IEEE Industrial Electronics Society*, Bd. 1, 2019, S. 3817–3822. DOI: 10.1109/IECON.2019.8927604.

[34] L. Hou, L. Xin, S. E. Li, B. Cheng und W. Wang, "Interactive Trajectory Prediction of Surrounding Road Users for Autonomous Driving Using Structural-LSTM Network," *IEEE Transactions on Intelligent Transportation Systems*, Jg. 21, Nr. 11, S. 4615–4625, 2020. DOI: 10.1109/TITS.2019.2942089.

[35] K. Messaoud, I. Yahiaoui, A. Verroust-Blondet und F. Nashashibi, "Attention Based Vehicle Trajectory Prediction," *IEEE Transactions on Intelligent Vehicles*, Jg. 6, Nr. 1, S. 175–185, 2021. DOI: 10.1109/TIV.2020.2991952.

[36] C. Dong, Y. Chen und J. M. Dolan, "Interactive Trajectory Prediction for Autonomous Driving via Recurrent Meta Induction Neural Network," in *2019 International Conference on Robotics and Automation (ICRA)*, 2019, S. 1212–1217. DOI: 10.1109/ICRA.2019.8794392.

[37] Y. Jeong, S. Kim und K. Yi, "Surround Vehicle Motion Prediction Using LSTM-RNN for Motion Planning of Autonomous Vehicles at Multi-Lane Turn Intersections," *IEEE Open Journal of Intelligent Transportation Systems*, Jg. 1, S. 2–14, 2020. DOI: 10.1109/OJITS.2020.2965969.

[38] A. Vahidi und A. Sciarretta, "Energy saving potentials of connected and automated vehicles," *Transportation Research Part C: Emerging Technologies*, Jg. 95, S. 822–843, 2018, ISSN: 0968-090X. DOI: https://doi.org/10.1016/j.trc.2018.09.001. Adresse: https://www.sciencedirect.com/science/article/pii/S0968090X18305199.

[39] C. Zhang, A. Vahidi, P. Pisu, X. Li und K. Tennant, "Role of Terrain Preview in Energy Management of Hybrid Electric Vehicles," *IEEE Transactions on Vehicular Technology*, Jg. 59, Nr. 3, S. 1139–1147, 2010. DOI: 10.1109/TVT.2009.2038707.

[40] Q. Jin, G. Wu, K. Boriboonsomsin und M. J. Barth, "Power-Based Optimal Longitudinal Control for a Connected Eco-Driving System," *IEEE Transactions on Intelligent Transportation Systems*, Jg. 17, Nr. 10, S. 2900–2910, 2016. DOI: 10.1109/TITS.2016.2535439.

[41] G. Mahler, A. Winckler, S. A. Fayazi, M. Filusch und A. Vahidi, "Cellular communication of traffic signal state to connected vehicles for arterial eco-driving," in *2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*, 2017, S. 1–6. DOI: 10.1109/ITSC.2017.8317591.

[42] P. Hao, G. Wu, K. Boriboonsomsin und M. J. Barth, "Eco-Approach and Departure (EAD) Application for Actuated Signals in Real-World Traffic," *IEEE Transactions on Intelligent Transportation Systems*, Jg. 20, Nr. 1, S. 30–40, 2019. DOI: 10.1109/TITS.2018.2794509.

[43] D. Lang, R. Schmied und L. Re, "Prediction of Preceding Driver Behavior for Fuel Efficient Cooperative Adaptive Cruise Control," *SAE International Journal of Engines*, Jg. 7, S. 14–20, Mai 2014. DOI: 10.4271/2014-01-0298.

[44] J. Han, A. Sciarretta, L. L. Ojeda, G. De Nunzio und L. Thibault, "Safe- and Eco-Driving Control for Connected and Automated Electric Vehicles Using Analytical State-Constrained Optimal Solution," *IEEE Transactions on Intelligent Vehicles*, Jg. 3, Nr. 2, S. 163–172, 2018. DOI: 10.1109/TIV.2018.2804162.

[45] J. Wu, Y. Wang, Z. Zhang, Y. Wen, L. Zhong und P. Zheng, "A Cooperative Merging Control Method for Freeway Ramps in Connected and Autonomous Driving," *Sustainability*, Jg. 14, Nr. 18, 2022, ISSN: 2071-1050. DOI: 10.3390/su141811120. Adresse: https://www.mdpi.com/2071-1050/14/18/11120.

[46] M. A. S. Kamal, S. Taguchi und T. Yoshimura, "Efficient vehicle driving on multi-lane roads using model predictive control under a connected vehicle environment," in *2015 IEEE Intelligent Vehicles Symposium (IV)*, 2015, S. 736–741. DOI: 10.1109/IVS.2015.7225772.

[47] S. Tsugawa, S. Jeschke und S. E. Shladover, "A Review of Truck Platooning Projects for Energy Savings," *IEEE Transactions on Intelligent Vehicles*, Jg. 1, Nr. 1, S. 68–77, 2016. DOI: 10.1109/TIV.2016.2577499.

[48] V. Turri, B. Besselink und K. H. Johansson, "Cooperative Look-Ahead Control for Fuel-Efficient and Safe Heavy-Duty Vehicle Platooning," *IEEE Transactions on Control Systems Technology*, Jg. 25, Nr. 1, S. 12–28, 2017. DOI: 10.1109/TCST.2016.2542044.

[49] S. Vegendla, T. Sofu, R. Saha, M. Kumar und L.-K. Hwang, "Investigation of Aerodynamic Influence on Truck Platooning," *SAE Technical Paper: 2015-01-2895*, Jg. 01, Nr. 2895, Sep. 2015. DOI: 10.4271/2015-01-2895..

[50] U. Franke, F. Bottiger, Z. Zomotor und D. Seeberger, "Truck platooning in mixed traffic," in *Proceedings of the Intelligent Vehicles '95. Symposium*, 1995, S. 1–6. DOI: 10.1109/IVS.1995.528248.

[51] E. van Nunen, F. Esposto, A. K. Saberi und J.-P. Paardekooper, "Evaluation of safety indicators for truck platooning," in *2017 IEEE Intelligent Vehicles Symposium (IV)*, 2017, S. 1013–1018. DOI: 10.1109/IVS.2017.7995847.

[52] M. Saeednia und M. Menendez, "A Consensus-Based Algorithm for Truck Platooning," *IEEE Transactions on Intelligent Transportation Systems*, Jg. 18, Nr. 2, S. 404–415, 2017. DOI: 10.1109/TITS.2016.2579260.

[53] J. Schindler, R. Dariani, M. Rondinone und T. Walter, "Dynamic and Flexible Platooning in Urban Areas," in *AAET Automatisiertes und vernetztes Fahren*, 2018. Adresse: https://elib.dlr.de/119655/.

[54] G. Sethuraman, X. Liu, F. R. Bachmann, M. Xie, A. Ongel und F. Busch, "Effects of Bus Platooning in an Urban Environment," in *2019 IEEE Intelligent Transportation Systems Conference (ITSC)*, 2019, S. 974–980. DOI: 10.1109/ITSC.2019.8917041.

[55] M. R. Hidayatullah und J.-C. Juang, "Centralized and Distributed Control Framework Under Homogeneous and Heterogeneous Platoon," *IEEE Access*, Jg. 9, S. 49 629–49 648, 2021. DOI: 10.1109/ACCESS.2021.3068968.

[56] G. Fiengo, D. G. Lui, A. Petrillo, S. Santini und M. Tufo, "Distributed Robust PID Control For Leader Tracking in Uncertain Connected Ground Vehicles With V2V Communication Delay," *IEEE/ASME Transactions on Mechatronics*, Jg. 24, Nr. 3, S. 1153–1165, 2019. DOI: 10.1109/TMECH.2019.2907053.

[57] D. G. Lui, A. Petrillo und S. Santini, "An optimal distributed PID-like control for the output containment and leader-following of heterogeneous high-order multi-agent systems," *Information Sciences*, Jg. 541, S. 166–184, 2020, ISSN: 0020-0255. DOI: https://doi.org/10.1016/j.ins.2020.06.049. Adresse: https://www.sciencedirect.com/science/article/pii/S002002552030637X.

[58] D. Lui, A. Petrillo und S. Santini, "Leader tracking control for heterogeneous uncertain nonlinear multi-agent systems via a distributed robust adaptive PID strategy," *Nonlinear Dynamics*, Jg. 108, Jan. 2022. DOI: 10.1007/s11071-022-07240-w.

[59] A. Coppola, D. G. Lui, A. Petrillo und S. Santini, "Cooperative driving of heterogeneous uncertain nonlinear connected and autonomous vehicles via distributed switching robust PID-like control," *Information Sciences*, Jg. 625, S. 277–298, 2023, ISSN: 0020-0255. DOI: https://doi.org/10.1016/j.ins.2023.01.045. Adresse: https://www.sciencedirect.com/science/article/pii/S0020025523000452.

[60] F. Gao, F.-x. Lin und B. Liu, "Distributed H∞ Control Of Platoon Interacted by Switching and Undirected Topology," *International Journal of Automotive Technology*, Jg. 21, S. 259–268, Feb. 2020. DOI: 10.1007/s12239-020-0025-8.

[61] C. Zhai, Y. Liu und F. Luo, "A Switched Control Strategy of Heterogeneous Vehicle Platoon for Multiple Objectives With State Constraints," *IEEE Transactions on Intelligent Transportation Systems*, Jg. 20, Nr. 5, S. 1883–1896, 2019. DOI: 10.1109/TITS.2018.2841980.

[62] B. Caiazzo, A. Coppola, A. Petrillo und S. Santini, "Distributed Nonlinear Model Predictive Control for Connected Autonomous Electric Vehicles Platoon with Distance-Dependent Air Drag Formulation," *Energies*, Jg. 14, Nr. 16, 2021, ISSN: 1996-1073. DOI: 10.3390/en14165122.

[63] R. Lacombe, S. Gros, N. Murgovski und B. Kulcsár, "Distributed Eco-Driving Control of a Platoon of Electric Vehicles Through Riccati Recursion," *IEEE Transactions on Intelligent Transportation Systems*, S. 1–16, 2022. DOI: 10.1109/TITS.2022.3224389.

[64] Y. Feng u. a., "Distributed MPC of vehicle platoons with guaranteed consensus and string stability," *Scientific Reports*, Jg. 13, 2023, ISSN: 2045-2322. DOI: 10.1038/s41598-023-36898-4. Adresse: https://doi.org/10.1038/s41598-023-36898-4.

[65] M. F. Ozkan und Y. Ma, "Distributed Stochastic Model Predictive Control for Human-Leading Heavy-Duty Truck Platoon," *IEEE Transactions on Intelligent Transportation Systems*, Jg. 23, Nr. 9, S. 16 059–16 071, 2022. DOI: 10.1109/TITS.2022.3147719.

[66] B. Liu, Z. Ding und C. Lv, "Platoon control of connected autonomous vehicles: A distributed reinforcement learning method by consensus," *IFAC-PapersOnLine*, Jg. 53, Nr. 2, S. 15 241–15 246, 2020, 21st IFAC World Congress, ISSN: 2405-8963. DOI: https://doi.org/10.1016/j.ifacol.2020.12.2310. Adresse: https://www.sciencedirect.com/science/article/pii/S2405896320329773.

[67] S. Lu, Y. Cai, L. Chen, H. Wang, X. Sun und Y. Jia, "A sharing deep reinforcement learning method for efficient vehicle platooning control," *IET Intelligent Transport Systems*, Jg. 16, Nr. 12, S. 1697–1709, 2022. DOI: https://doi.org/10.1049/itr2.12120. eprint: https://ietresearch.onlinelibrary.wiley.com/doi/pdf/10.1049/itr2.12120. Adresse: https://ietresearch.onlinelibrary.wiley.com/doi/abs/10.1049/itr2.12120.

[68] N. Chen, M. Wang, T. Alkim und B. van Arem, "A Robust Longitudinal Control Strategy of Platoons under Model Uncertainties and Time Delays," *Journal of Advanced Transportation*, Jg. 2018, 2018. DOI: 10.1155/2018/9852721.

[69] R. H. Patel, H. Wymeersch, J. Härri und C. Bonnet, "Buffer-Aided Model Predictive Controller to Mitigate Model Mismatches and Localization Errors," *IEEE Transactions on Intelligent Vehicles*, Jg. 3, Nr. 4, S. 501–510, 2018. DOI: 10.1109/TIV.2018.2873908.

[70] J. Zhou u. a., "Robust Min-Max Model Predictive Vehicle Platooning With Causal Disturbance Feedback," *IEEE Transactions on Intelligent Transportation Systems*, S. 1–20, 2022. DOI: 10.1109/TITS.2022.3146149.

[71] J. Kennedy, J. Heinovski, D. Quevedo und F. Dressler, "Centralized Model-Predictive Control with Human-Driver Interaction for Platooning," Mai 2022. DOI: 10.48550/arXiv.2205.09259.

[72] E. van Nunen, J. Verhaegh, E. Silvas, E. Semsar-Kazerooni und N. van de Wouw, "Robust model predictive cooperative adaptive cruise control subject to V2V impairments," in *2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*, 2017, S. 1–8. DOI: 10.1109/ITSC.2017.8317758.

[73] E. van Nunen, J. Reinders, E. Semsar-Kazerooni und N. van de Wouw, "String Stable Model Predictive Cooperative Adaptive Cruise Control for Heterogeneous Platoons," *IEEE Transactions on Intelligent Vehicles*, Jg. 4, Nr. 2, S. 186–196, 2019. DOI: 10.1109/TIV.2019.2904418.

[74] T. Chu und U. Kalabić, "Model-based deep reinforcement learning for CACC in mixed-autonomy vehicle platoon," in *2019 IEEE 58th Conference on Decision and Control (CDC)*, 2019, S. 4079–4084. DOI: 10.1109/CDC40024.2019.9030110.

[75] M. Sun, F. Lewis und S. Ge, "Platoon-stable adaptive controller design," in *2004 43rd IEEE Conference on Decision and Control (CDC) (IEEE Cat. No.04CH37601)*, Bd. 5, 2004, 5481–5486 Vol.5. DOI: 10.1109/CDC.2004.1429680.

[76] Y. A. Harfouch, S. Yuan und S. Baldi, "An Adaptive Switched Control Approach to Heterogeneous Platooning With Intervehicle Communication Losses," *IEEE Transactions on Control of Network Systems*, Jg. 5, Nr. 3, S. 1434–1444, 2018. DOI: 10.1109/TCNS.2017.2718359.

[77] S. B. Prathiba, G. Raja, K. Dev, N. Kumar und M. Guizani, "A Hybrid Deep Reinforcement Learning For Autonomous Vehicles Smart-Platooning," *IEEE Transactions on Vehicular Technology*, Jg. 70, Nr. 12, S. 13 340–13 350, 2021. DOI: 10.1109/TVT.2021.3122257.

[78] C. Li, "Optimal Tracking Control of Vehicle Cooperative Platoon Based on Reinforcement Learning," in *2022 IEEE 11th Data Driven Control and Learning Systems Conference (DDCLS)*, 2022, S. 1171–1176. DOI: 10.1109/DDCLS55054.2022.9858414.

[79] F. Fakhfakh, M. Tounsi und M. Mosbah, "Vehicle Platooning Systems: Review, Classification and Validation Strategies," *International Journal of Networked and Distributed Computing*, Jg. 8, S. 203–213, 4 2020, ISSN: 2211-7946. DOI: 10.2991/ijndc.k.200829.001. Adresse: https://doi.org/10.2991/ijndc.k.200829.001.

[80] S. Badnava u. a., "Platoon Transitional Maneuver Control System: A Review," *IEEE Access*, Jg. 9, S. 88 327–88 347, 2021. DOI: 10.1109/ACCESS.2021.3089615.

[81] M. Segata, B. Bloessl, S. Joerer, F. Dressler und R. L. Cigno, "Supporting platooning maneuvers through IVC: An initial protocol analysis for the JOIN maneuver," in *2014 11th Annual Conference on Wireless On-demand Network Systems and Services (WONS)*, 2014, S. 130–137. DOI: 10.1109/WONS.2014.6814733.

[82] M. Goli und A. Eskandarian, "Evaluation of lateral trajectories with different controllers for multi-vehicle merging in platoon," in *2014 International Conference on Connected Vehicles and Expo (ICCVE)*, 2014, S. 673–678. DOI: 10.1109/ICCVE.2014.7297633.

[83] M. Amoozadeh, H. Deng, C.-N. Chuah, H. M. Zhang und D. Ghosal, "Platoon management with cooperative adaptive cruise control enabled by VANET," *Vehicular Communications*, Jg. 2, Nr. 2, S. 110–123, 2015, ISSN: 2214-2096. DOI: https://doi.org/10.1016/j.vehcom.2015.03.004. Adresse: https://www.sciencedirect.com/science/article/pii/S2214209615000145.

[84] H. Liu, W. Zhuang, G. Yin, Z. Tang und L. Xu, "Strategy for heterogeneous vehicular platoons merging in automated highway system," in *2018 Chinese Control And Decision Conference (CCDC)*, 2018, S. 2736–2740. DOI: 10.1109/CCDC.2018.8407590.

[85] H. Min, Y. Yang, Y. Fang, P. Sun und X. Zhao, "Constrained Optimization and Distributed Model Predictive Control-Based Merging Strategies for Adjacent Connected Autonomous Vehicle Platoons," *IEEE Access*, Jg. 7, S. 163 085–163 096, 2019. DOI: 10.1109/ACCESS.2019.2952049.

[86] M. Goli und A. Eskandarian, "MPC-based Lateral Controller with Look-Ahead Design for Autonomous Multi-vehicle Merging into Platoon," in *2019 American Control Conference (ACC)*, 2019, S. 5284–5291. DOI: 10.23919/ACC.2019.8814967.

[87] W. Zhao, D. Ngoduy, S. Shepherd, R. Liu und M. Papageorgiou, "A platoon based cooperative eco-driving model for mixed automated and human-driven vehicles at a signalised intersection," *Transportation Research Part C: Emerging Technologies*, Jg. 95, S. 802–821, 2018, ISSN: 0968-090X. DOI: https://doi.org/10.1016/j.trc.2018.05.025. Adresse: https://www.sciencedirect.com/science/article/pii/S0968090X18307423.

[88] C. Wang, Y. Dai und J. Xia, "A CAV Platoon Control Method for Isolated Intersections: Guaranteed Feasible Multi-Objective Approach with Priority," *Energies*, Jg. 13, Nr. 3, 2020, ISSN: 1996-1073. DOI: 10.3390/en13030625. Adresse: https://www.mdpi.com/1996-1073/13/3/625.

[89] A. L. Gratzer, A. Schirrer, S. Thormann und S. Jakubek, "Platoon Control Concepts," in *Energy-Efficient and Semi-automated Truck Platooning: Research and Evaluation*, A. Schirrer, A. L. Gratzer, S. Thormann, S. Jakubek, M. Neubauer und W. Schildorfer, Hrsg. Cham: Springer International Publishing, 2022, S. 105–120, ISBN: 978-3-030-88682-0. DOI: 10.1007/978-3-030-88682-0_8. Adresse: https://doi.org/10.1007/978-3-030-88682-0_8.

[90] H. Zhang und L. Du, "Platoon Centered Control for Eco-driving at Signalized Intersection Built upon Hybrid MPC System," in *2022 IEEE 25th International Conference on Intelligent Transportation Systems (ITSC)*, 2022, S. 667–672. DOI: 10.1109/ITSC55140.2022.9922270.

[91] A. Irshayyid und J. Chen, "Comparative Study of Cooperative Platoon Merging Control Based on Reinforcement Learning," *Sensors*, Jg. 23, Nr. 2, 2023, ISSN: 1424-8220. DOI: 10.3390/s23020990. Adresse: https://www.mdpi.com/1424-8220/23/2/990.

[92] Y. Feng, D. He und Y. Guan, "Composite Platoon Trajectory Planning Strategy for Intersection Throughput Maximization," *IEEE Transactions on Vehicular Technology*, Jg. 68, Nr. 7, S. 6305–6319, 2019. DOI: 10.1109/TVT.2019.2914163.

[93] Q. Li, Z. Chen und X. Li, "A Review of Connected and Automated Vehicle Platoon Merging and Splitting Operations," *IEEE Transactions on Intelligent Transportation Systems*, Jg. 23, Nr. 12, S. 22 790–22 806, 2022. DOI: 10.1109/TITS.2022.3193278.

[94] D. Li, J. Wu, F. Zhu, T. Chen und Y. D. Wong, "Modeling adaptive platoon and reservation-based intersection control for connected and autonomous vehicles employing deep reinforcement learning," *Computer-Aided Civil and Infrastructure Engineering*, Jg. 38, Nr. 10, S. 1346–1364, 2023. DOI: https://doi.org/10.1111/mice.12956. eprint: https://onlinelibrary.wiley.com/doi/pdf/10.1111/mice.12956. Adresse: https://onlinelibrary.wiley.com/doi/abs/10.1111/mice.12956.

[95] W. Ren, J. Zhang, L. Li und Q. Zhou, "An Intersection Platoon Speed Control Model Considering Traffic Efficiency and Energy Consumption in CVIS," *Mathematical Problems in Engineering*, Jg. 2021, 2021. DOI: 10.1155/2021/2891247.

[96] S. Detering, "Kalibrierung und Validierung von Verkehrssimulationsmodellen zur Untersuchung von Verkehrsassistenzsystemen," de, Diss., 2011. DOI: 10.24355/dbbs.084-201103090951-0. Adresse: https://leopard.tu-braunschweig.de/receive/dbbs_mods_00038450.

[97] E. Schnieder, *Verkehrsleittechnik - Automatisierung des Straßen- und Schienenverkehrs*. Springer Berlin, Heidelberg, 2007. DOI: https://doi.org/10.1007/978-3-540-48541-4.

[98] W. S. Dieter Lohse, *Grundlagen der Straßenverkehrstechnik und der Verkehrsplanung: Band 2-Verkehrsplanung*. Beuth Verlag, 2011, ISBN: 978-3-410-17272-7.

[99] F. Höfler, in *Verkehrswesen-Praxis: Band 2: Verkehrstechnik Bauwerk-Basis-Bibliothek* (Bauwerk), Bauwerk. Beuth Verlag GmbH, 2006, ISBN: 9783410216148. Adresse: https://books.google.de/books?id=mKkiuQAACAAJ.

[100] B. Greenshields, "The photographic method of studying traffic behavior," *13th Annual Meeting of the Highway Research Board*, 1934.

[101] I. of Transportation Systems at the German Aerospace Center, *Traffic Simulations SUMO*, https://sumo.dlr.de/docs/Theory/Traffic_Simulations.html, 2021.

[102] C. Keßler, "OpenStreetMap," in *Encyclopedia of GIS*, S. Shekhar, H. Xiong und X. Zhou, Hrsg. Cham: Springer International Publishing, 2015, S. 1–5, ISBN: 978-3-319-23519-6. DOI: 10.1007/978-3-319-23519-6_1654-1. Adresse: https://doi.org/10.1007/978-3-319-23519-6_1654-1.

[103] M. Pourabdollah, E. Bjärkvik, F. Fürer, B. Lindenberg und K. Burgdorf, "Calibration and evaluation of car following models using real-world driving data," in *2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*, 2017, S. 1–6. DOI: 10.1109/ITSC.2017.8317836.

[104] M. Treiber, A. Hennecke und D. Helbing, "Congested traffic states in empirical observations and microscopic simulations," *Phys. Rev. E*, Jg. 62, S. 1805–1824, 2 2000. DOI: 10.1103/PhysRevE.62.1805. Adresse: https://link.aps.org/doi/10.1103/PhysRevE.62.1805.

[105] M. Wegener, "Energy-efficient longitudinal control of connected and automated vehicles using reinforcement learning," Diss., Okt. 2022.

[106] R. Trapp, *Entwicklung eines proaktiven Verfahrens zur Rampenzuflusssteuerung und die Bewertung seiner Wirkung im Vergleich zu anderen Steuerungsverfahren* (Aachener Mitteilungen Straßenwesen, Erd- und Tunnelbau). Aachen: Isac, 2006, Bd. 49, VIII, 170 S. : graph. Darst. Zugl.: Aachen, Techn. Hochsch., Diss., 2006, ISBN: 3-925163-38-7. Adresse: https://publications.rwth-aachen.de/record/678359.

[107] J. Erdmann, "Lane-changing model in SUMO," Bd. 24, Mai 2014.

[108] J. Erdmann, "SUMO's Lane-Changing Model," in *Modeling Mobility with Open Data*, M. Behrisch und M. Weber, Hrsg., Cham: Springer International Publishing, 2015, S. 105–123, ISBN: 978-3-319-15024-6.

[109] M. Friedrich, E. Pestel, U. Heidl, J. Pillat, C. Schiller und R. Simon, "FE 70.919/2015 Anforderungen an städtische Verkehrsnachfragemodelle," 2019.

[110] L. Koch u. a., "Accurate physics-based modeling of electric vehicle energy consumption in the SUMO traffic microsimulator," in *2021 IEEE International Intelligent Transportation Systems Conference (ITSC)*, 2021, S. 1650–1657. DOI: 10.1109/ITSC48978.2021.9564463.

[111] U. Bundesamt, *Pkw-Bestand nach Segmenten*, https://www.umweltbundesamt.de/bild/pkw-bestand-nach-segmenten, [Online; letzter Abruf 19-Mai-2023], 2023.

[112] K. P. Murphy, *Machine learning : a probabilistic perspective*. Cambridge, Mass. [u.a.]: MIT Press, 2013, ISBN: 9780262018029 0262018020. Adresse: https://www.amazon.com/Machine-Learning-Probabilistic-Perspective-Computation/dp/0262018020/ref=sr_1_2?ie=UTF8&qid=1336857747&sr=8-2.

[113] N. J. Nilsson, *Artificial Intelligence: A New Synthesis*. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 1998, ISBN: 9780080499451.

[114] S. Selle, *Künstliche Neuronale Netzwerke und Deep Learning*. Hochschule für Technik und Wirtschaft des Saarlandes, 2018.

[115] J. Schmidhuber, "Deep learning in neural networks: An overview," *Neural Networks*, Jg. 61, S. 85–117, 2015, ISSN: 0893-6080. DOI: https://doi.org/10.1016/j.neunet.2014.09.003. Adresse: https://www.sciencedirect.com/science/article/pii/S0893608014002135.

[116] C. Olah, *Understanding LSTM Networks*, 2015. Adresse: http://colah.github.io/posts/2015-08-Understanding-LSTMs/.

[117] S. Hochreiter und J. Schmidhuber, "Long Short-Term Memory," *Neural Computation*, Jg. 9, Nr. 8, S. 1735–1780, 1997.

[118] B. Lindemann, N. Jazdi und M. Weyrich, "Detektion von Anomalien zur Qualitätssicherung basierend auf Sequence-to-Sequence LSTM Netzen," *at - Automatisierungstechnik*, Jg. 67, Nr. 12, S. 1058–1068, 2019. DOI: doi:10.1515/auto-2019-0076. Adresse: https://doi.org/10.1515/auto-2019-0076.

[119] Tensorflow, *Time series forecasting*, https://www.tensorflow.org/tutorials/structured_data/time_series, [Online; letzter Abruf 10-März-2024], 2024.

[120] D. Kingma und J. Ba, "Adam: A Method for Stochastic Optimization," *International Conference on Learning Representations*, Dez. 2014.

[121] T. Plum, "Einfluss moderner Antriebsstränge auf den Energiebedarf automatisierter Fahrzeuge," Dissertation, Rheinisch-Westfälische Technische Hochschule Aachen, 2019, Dissertation, Rheinisch-Westfälische Technische Hochschule Aachen, Aachen, 2019, VII, XIV, 127 Seiten : Illustrationen, Diagramme. Adresse: https://publications.rwth-aachen.de/record/761324.

[122] M. Wegener, T. Plum, M. Eisenbarth und J. Andert, "Energy saving potentials of modern powertrains utilizing predictive driving algorithms in different traffic scenarios," *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, Jg. 234, S. 095 440 701 986 717, Aug. 2019. DOI: 10.1177/0954407019867172.

[123] Y. Zheng, S. E. Li, K. Li, F. Borrelli und J. K. Hedrick, "Distributed Model Predictive Control for Heterogeneous Vehicle Platoons Under Unidirectional Topologies," *IEEE Transactions on Control Systems Technology*, Jg. 25, Nr. 3, S. 899–910, 2017. DOI: 10.1109/TCST.2016.2594588.

[124] C. Zhai, X. Chen, C. Yan, Y. Liu und H. Li, "Ecological Cooperative Adaptive Cruise Control for a Heterogeneous Platoon of Heavy-Duty Vehicles With Time Delays," *IEEE Access*, Jg. 8, S. 146 208–146 219, 2020. DOI: 10.1109/ACCESS.2020.3015052.

[125] H. Ferreau, C. Kirches, A. Potschka, H. Bock und M. Diehl, "qpOASES: A parametric active-set algorithm for quadratic programming," *Mathematical Programming Computation*, Jg. 6, Nr. 4, S. 327–363, 2014.

[126] J. Maciejowski, *Predictive Control with Constraints.* Prentice Hall, 2002.

[127] D. McLEAN, "Kevin Gurney, An Introduction to Neural Networks, University College London (UCL) Press, 1997. ISBN 1-85728-673-1 HB. £14.95. xi+234 pages.," *Natural Language Engineering*, Jg. 6, Nr. 2, 203–204, 2000. DOI: 10.1017/S1351324900002540.

[128] C. M. Bishop, "Neural networks and their applications," *Review of Scientific Instruments*, Jg. 65, Nr. 6, S. 1803–1832, Juni 1994, ISSN: 0034-6748. DOI: 10.1063/1.1144830. eprint: https://pubs.aip.org/aip/rsi/article-pdf/65/6/1803/19141715/1803_1_online.pdf. Adresse: https://doi.org/10.1063/1.1144830.

[129] D. Abel, *Umdruck zur Vorlesung Regelungstechnik und Ergänzugen (Höhere Regelungstechnik)*, 4th. Aachen, DE: Verlagshaus Mainz, 2013.

Anhang

A.1 Parametrierung der Simulationsumgebung

A.1.1 Referenzmessungen und Parametrierung der IDM-Fahrermodelle

Im Rahmen einer wissenschaftlichen Untersuchung wurden Fahrzeugmessungen im Aachener Raum mit insgesamt zwölf verschiedenen Fahrern durchgeführt. Während dieser Messungen wurden diverse Messgrößen erfasst, darunter die Fahrgeschwindigkeit, die Beschleunigung, der Abstand zum vorausfahrenden Fahrzeug, die Geschwindigkeit des VFs, die Geschwindigkeitsbegrenzung sowie die elektrische Leistung des Fahrzeugs. Die Analyse dieser Messdaten ermöglichte es, die kritischen Parameter des IDM-Modells unter Verwendung des in [105] präsentierten genetischen Algorithmus zu bestimmen. Der Prozess der Parameteridentifikation beruht auf einem multivariaten, nicht-linearen Optimierungsansatz, bei dem die Fitnessfunktion durch das quadratische Fehlermittel der bestimmten Beschleunigungstrajektorie charakterisiert ist. Zunächst wurden die Parameter a_0, v_0 und δ unter Bedingungen freier Fahrt ermittelt. Darauf basierend wurden die Parameter b_0 und T_0 auf Basis der in der freien Fahrt bestimmten Werte ebenfalls durch Anwendung des genetischen Algorithmus bestimmt.

Tabelle A.1.1: Parametereinstellung für das IDM-Fahrermodell in SUMO

Parameter	Zeichen	Einheit	Parameter der IDM-Fahrermodelle											
			1	2	3	4	5	6	7	8	9	10	11	12
Wunschabstand	d_0	m	2.5	2.5	2.5	2.5	2.5	2.5	2.5	2.5	2.5	2.5	2.5	2.5
Wunschgeschwindigkeit	v_0	km/h	56	54,3	60	52	60	60	58	60	60	55	54	60
Wunschzeitabstand	T_0	s	1,7	1,4	1,5	0,9	1,0	1,6	2,2	1,5	2,4	1,3	1,9	2,4
Maximale Beschleunigung	a_0	m/s^2	1,4	1,4	1,6	2,2	1,8	1,7	2,0	1,6	1,5	2,3	1,8	1,7
Maximale Verzögerung	b_0	m/s^2	2,5	3,3	1,9	4	2,7	2,6	4	2,4	2,9	1,8	1,6	3,2
Maximale Verzögerung in kritische Situation	b_{krit}	m/s^2	8	8	8	8	8	8	8	8	8	8	8	8
Beschleunigungs-exponent	δ		4	3,4	3,5	2,8	2,7	4	1,8	4	4	2,5	4	3,3

Tabelle A.1.2: Parametereinstellung für das NAF IDM-Fahrermodell in SUMO

Parameter	Zeichen	Einheit	NAF PKW			NAF Motorrad			NAF LKW	
			1	2	3	1	2	3	1	2
Wunschabstand	d_0	m	2.5	2.5	2.5	2.5	2.5	2.5	3.5	3.5
Wunschgeschwindigkeit	v_0	km/h	54	61	50	54	61	50	50	50
Wunschzeitabstand	T_0	s	2,2	1,5	2,5	1,8	1,5	2,0	2,2	2,0
Maximale Beschleunigung	a_0	m/s^2	2,6	3,5	2,6	6	4	6	1,3	1,3
Maximale Verzögerung	b_0	m/s^2	4,5	4,5	4,5	4,5	4,5	4,5	4	4
Maximale Verzögerung in kritische Situation	b_{krit}	m/s^2	4,5	4,5	4,5	4,5	4,5	4,5	4	4
Beschleunigungs-exponent	δ		4	4	4	4	4	4	4	4
Anteil von gesamten Fahrzeuge			4 %	2 %	4 %	1 %	1 %	1 %	1 %	1 %

Tabelle A.1.3: Mittelwert der Parametereinstellung für das IDM in SUMO

Parameter	Zeichen	Automatisierte Verkehrsteilnehmer	Nicht automatisierte Verkehrsteilnehmer
Wunschabstand	d_0	2,5 m	2.5 m
Wunschgeschwindigkeit	v_0	59,85 km/h	50 - 61 km/h
Wunschzeitabstand	T_0	1,57 s	1,5 - 2,5 s
Maximale Beschleunigung	a_0	1,65 m/s^2	2,6 - 6 m/s^2
Maximale Verzögerung	b_0	2,91 m/s^2	4,5 - 6 m/s^{22}
Maximale Verzögerung in kritische Situation	b_{krit}	8 m/s^2	4,5 - 10 m/s^2
Beschleunigungsexponent	δ	4	4
Anteil an gesamten Fahrzeugen		85 %	15 %

A.1.2 Parametrierung der Fahrzeugmodelle

Im Jahr 2023 beträgt der Anteil von Kleinwagen, Mini- und Kompaktklasse-Fahrzeugen am PKW-Bestand etwa 49 %. Der Anteil der Mittelklasse, oberen Mittelklasse und Oberklasse liegt zusammen bei 16 %, während Geländewagen, Vans und andere Fahrzeugtypen einen Gesamtanteil von 35 % aufweisen [111]. Die Fahrzeugklassen und die Anteile am PKW-Bestand in SUMO sind in Tabelle A.1.4 aufgeführt. Zusätzlich wird für jede Fahrzeugklasse ein beispielhaftes Fahrzeugmodell angenommen.

Tabelle A.1.4: Fahrzeugklasse und Anteil am Pkw-Bestand in SUMO

Fahrzeugklasse	bsp. Fahrzeugmodell	WLTC Energiebedarf in kWh/100 km	Anteil am Pkw-Bestand
Mini, Kleinwagen, Kompaktklasse	BMW i3	15,5	49 %
Mittelklasse, obere Mittelklasse, Oberklasse	VW ID.4	18,7	16 %
Geländewagen, VANs und Sonstiges	SUV	23,7	35 %

Die Fahrzeugparameter gemäß [110] sind in folgenden Tabellen aufgelistet.

Tabelle A.1.5: Fahrzeugparamter Teil 1

Fahrzeugmodell	Komponente	Parameter	Wert
BMW i3	Fahrwiderstände	dynamischer Radhalbmesser	0,35 m
		Fahrzeugmasse	1417 kg
		Rollwiderstandsbeiwert	0,007
		Luftwiderstandsbeiwert	0,29
		Querspanfläche	2,38 m^2
	Getriebe	Übersetzung	9,665
		Wirkungsgrad	0,96
	Elektromotor & Umrichter	maximale Leistung	125 kW
		minimale Leistung	-50 kW
		maximales Drehmoment	250 Nm
		minimales Drehmoment	-77 Nm
		Verlustleistung	f(M,n)
	HV Batterie	Leerlaufspannung	370 V
		Innenwiderstand	76,8 mΩ
	DC-DC	Leistungsaufnahme	360 W

Tabelle A.1.6: Fahrzeugparamter Teil 2

Fahrzeugmodell	Komponente	Parameter	Wert
VW ID.4	Fahrwiderstände	dynamischer Radhalbmesser	0,37 m
		Fahrzeugmasse	2124 kg
		Rollwiderstandsbeiwert	0,008
		Luftwiderstandsbeiwert	0,28
		Querspanfläche	2,54 m^2
	Getriebe	Übersetzung	10
		Wirkungsgrad	0,96
	Elektromotor & Umrichter	maximale Leistung	150 kW
		minimale Leistung	-90 kW
		maximales Drehmoment	310 Nm
		minimales Drehmoment	-124 Nm
		Verlustleistung	f(M,n)
	HV Batterie	Leerlaufspannung	396 V
		Innenwiderstand	151,6 mΩ
	DC-DC	Leistungsaufnahme	360 W

Tabelle A.1.7: Fahrzeugparamter Teil 3

Fahrzeugmodell	Komponente	Parameter	Wert
SUV	Fahrwiderstände	dynamischer Radhalbmesser	0,38 m
		Fahrzeugmasse	2100 kg
		Rollwiderstandsbeiwert	0,01
		Luftwiderstandsbeiwert	0,29
		Querspanfläche	3,23 m^2
	Getriebe	Übersetzung	9,325
		Wirkungsgrad	0,96
	Elektromotor & Umrichter	maximale Leistung	180 kW
		minimale Leistung	-105 kW
		maximales Drehmoment	380 Nm
		minimales Drehmoment	-180 Nm
		Verlustleistung	f(M,n)
	HV Batterie	Leerlaufspannung	408 V
		Innenwiderstand	157,5 mΩ
	DC-DC	Leistungsaufnahme	360 W

A.1.3 Aufbau des elektrischen Antriebstrangs

Abbildung A.1.1 stellt den Antriebsstrang von einem batterieelektrischen Fahrzeug dar.

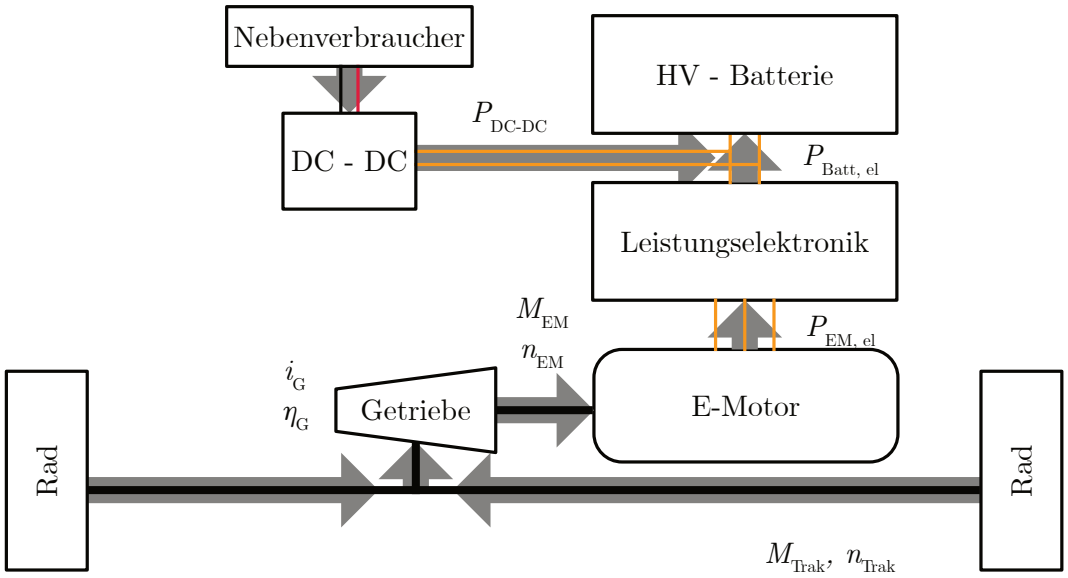

Abbildung A.1.1: Darstellung des Antriebsstrangs von einem batterieelektrischen Fahrzeug

A.2 Grundlagen zur Trajektorienprädiktion

A.2.1 Künstliche neuronale Netzwerke

Ein künstliches neuronales Netzwerk (KNN) besteht aus einer verschalteten Anordnung einfacher Verarbeitungseinheiten, die lose auf der Grundlage biologischer Neuronen basiert und die Fähigkeit besitzen, komplexe Funktionen zu approximieren, Aufgaben zu erlernen und Probleme zu lösen, bei denen eine explizite Modellierung unpraktikabel ist [127].
Das Modell eines einzelnen künstlichen Neurons, das auf biologischen Neuronen basiert, ist in Abbildung A.2.1 dargestellt. Die Gewichtungen W_{nj} stellen einstellbare Intensitäten der signalübertragenden Synapsen dar und beeinflussen die Aktivierung des Neurons auf Grundlage der gewichteten Eingaben. Der Schwellwert θ_{j} in Kombination mit der Aktivierungsfunktion φ entspricht dem signalverarbeitenden Zellkörper und beeinflusst die Aktivierung des Neurons. Die Aktivierung σ_{j} dient als Ausgabe des Neurons und repräsentiert die Reaktion auf die Aktivierungen vorgeschalteter Neuronen. Die Aktivierungsfunktion φ verarbeitet die Netzeingabe und den Schwellwert, wobei der Schwellwert durch ein Biasneuron σ_0 mit einem konstanten Wert 1 dargestellt wird. Die Auswahl der Aktivierungsfunktion kann je nach Problemstellung variieren und umfasst Funktionen wie die Schwellwertfunktion, den Tangens hyperbolicus, die Sigmoidfunktion und die Rectifier-Funktion. Ein künstliches neuronales Netzwerk besteht aus einer Verknüpfung mehrerer solcher Neuronen, um komplexe Problemstellungen zu bewältigen [128].

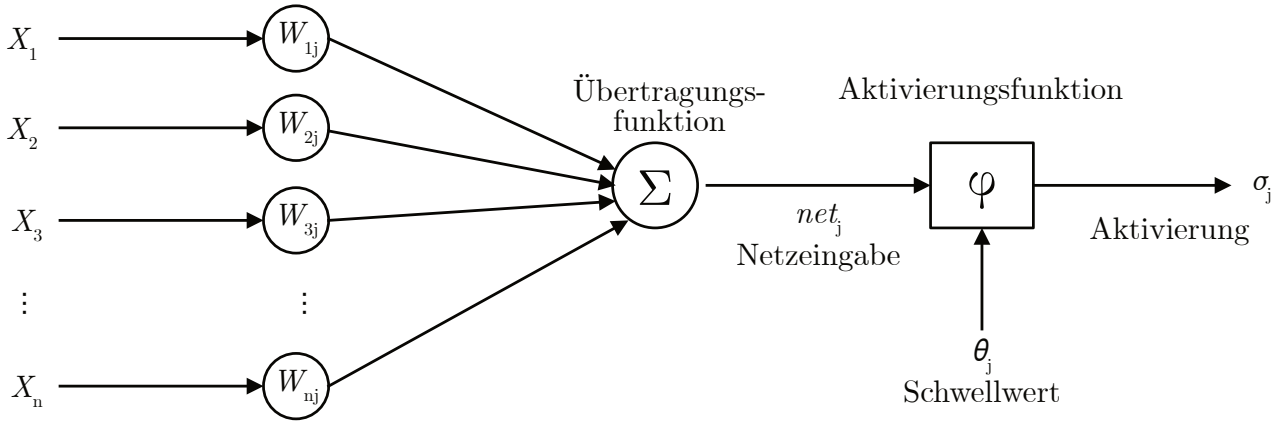

Abbildung A.2.1: Aufbau eines künstlichen Neurons j mit n Eingängen

Zur Entwicklung leistungsfähiger künstlicher neuronaler Netzwerke werden die künstlichen Neuronen in verschiedenen Strukturen miteinander verbunden. Die Neuronen werden in Schichten angeordnet, einschließlich einer Eingabe-, Ausgabe- und einer oder mehrerer verdeckten Schichten. Durch Verwendung mehrerer verdeckter Schichten entsteht ein tiefes neuronales Netzwerk [115].
In einem künstlichen neuronalen Netzwerk nehmen die Neuronen der Eingabeschicht die eingehenden Informationen auf und leiten diese an die nachfolgenden Schichten weiter. Die Informationen werden durch das Netzwerk bis zur Ausgabeschicht propagiert, in dem das endgültige Ergebnis generiert wird. Die Ausgabeschicht besteht typischerweise aus Neuronen mit linearen Aktivierungsfunktionen, die die Signale nicht weiter verarbeiten. Die Anzahl der Neuronen in den Eingabe- und Ausgabeschichten wird durch die spezifische Problemstellung definiert, während die Anzahl der Neuronen

in den verdeckten Schichten flexibel wählbar ist. Die Ermittlung der optimalen Netzwerkstruktur erfordert einen iterativen Prozess des Trainierens und der Evaluierung verschiedener Architekturen [128].
Es existieren verschiedene Topologien für die Verknüpfung künstlicher Neuronen, insbesondere vorwärtsgerichtete und rekurrente Netzwerke. Vorwärtsgerichtete Netzwerke, wie das Mehrschichten-Perzeptron (engl: Multilayer Perceptron (MLP)) und faltende neuronale Netze (engl: Convolutional Neural Networks (CNN)), zeichnen sich durch eine eindirektionale Informationsflussrichtung hin zur Ausgabeschicht aus. Im Gegensatz dazu gestatten RNN rückwärtsgerichtete Verbindungen durch eingebettete Rückkopplungsmechanismen. MLP sind vielseitig einsetzbar und bedienen ein breites Spektrum an Anwendungen, das sowohl Klassifikations- und als auch Regressionsprobleme umfasst. CNN hingegen sind prädestiniert für Aufgaben im Bereich der Bildverarbeitung, denn diese können durch konvolutionelle Operationen effektive Merkmale in visuellen Daten extrahieren [128].

A.2.2 Berechnung innerhalb der LSTM-Netzstruktur

Das Forget-Gate steuert den einfließenden Informationsfluss in die Zelle und entscheidet, welche eingehenden Informationen relevant sind. Hierbei werden die Eingaben x_t und $h_{\mathrm{t}-1}$ mittels einer Sigmoidfunktion verarbeitet, die kontinuierliche Werte zwischen 0 (vergiss alle Informationen) und 1 (behalte alle Informationen) generiert. Die Ausgabe des Forget-Gate wird in Gl. A.2.1 berechnet:

$$f_\mathrm{t} = f^{\mathrm{Sig}}(W_\mathrm{f} * [h_{\mathrm{t}-1}, x_\mathrm{t}] + b_\mathrm{f}) \tag{A.2.1}$$

Das Input-Gate (in Abbildung 5.1 rot umrandet) entscheidet, welche neuen Informationen in der Zelle gespeichert werden sollen. Hierbei werden die Eingaben x_t und $h_{\mathrm{t}-1}$ mittels einer weiteren Sigmoidfunktion verarbeitet und generieren das Zwischenergebnis i_t. Zusätzlich wird durch die Tangens hyperbolicus Funktion ein neuer Kandidat für den Zellwert $\tilde{c}_\mathrm{t}$ bestimmt:

$$\begin{aligned} i_\mathrm{t} &= f^{\mathrm{Sig}}(W_\mathrm{i} * [h_{\mathrm{t}-1}, x_\mathrm{t}] + b_\mathrm{i}) \\ \tilde{c}_\mathrm{t} &= f^{\tanh}(W_\mathrm{i} * [h_{\mathrm{t}-1}, x_\mathrm{t}] + b_\mathrm{i}) \end{aligned} \tag{A.2.2}$$

Der Zellwert c_t wird anschließend aktualisiert, indem der vorherige Wert $c_{\mathrm{t}-1}$ mit der Ausgabe des Forget-Gate f_t und der neue Kandidat $\tilde{c}_\mathrm{t}$ mit dem Zwischenergebnis des Input-Gate i_t gewichtet wird. Die resultierenden Werte werden addiert und als c_t gespeichert:

$$c_\mathrm{t} = f_\mathrm{t} \circ c_{\mathrm{t}-1} + i_\mathrm{t} \circ \tilde{c}_\mathrm{t} \tag{A.2.3}$$

Das Output-Gate (in Abbildung 5.1 blau umrandet) entscheidet, welcher Wert o_t weitergegeben werden soll. Hierfür werden die ursprünglichen Eingaben x_t und $h_{\mathrm{t}-1}$ durch eine weitere Sigmoidfunktion verarbeitet. Der aktuelle Zellzustand (c_t) wird anschließend mit dem Tangens hyperbolicus verknüpft, und die Ausgabe h_t wird als das Produkt dieser beiden Teilergebnisse berechnet.

$$\begin{aligned} o_\mathrm{t} &= f^{\mathrm{Sig}}(W_\mathrm{o} * [h_{\mathrm{t}-1}, x_\mathrm{t}] + b_\mathrm{o}) \\ h_\mathrm{t} &= o_\mathrm{t} \circ f^{\tanh}(c_\mathrm{t}) \end{aligned} \tag{A.2.4}$$

A.2.3 Detaillierte Beschreibung des Trainingsprozesses

Ein weit verbreiteter Algorithmus hierfür ist die Fehlerrückführung (engl.: Backpropagation, BP), welche durch den Vergleich der Netzausgabe $\hat{y}_\mathrm{i}$ mit den Labels y_i einen Fehlerwert L generiert und diesen zur Gewichtsanpassung rückführt:

$$L = \frac{1}{N} \cdot \sum_{\mathrm{i}=1}^{N} (\frac{1}{T'} \cdot \sum_{\mathrm{j}=1}^{T'} (y_\mathrm{ij} - y_\mathrm{ij})^2) \tag{A.2.5}$$

L entspricht dabei dem gemittelten quadrierten Prädiktionsfehler über N Trainingsdaten einer Länge T'.
Die Fehlermetrik ist oft das quadratische Mittel der Differenz zwischen Netzwerkausgabe und Label. Der Fehler wird über das Netz zurückgeführt und die Gewichtungen können, in Abhängigkeit deren Einflusses auf den Fehler und unter Berücksichtigung der Lernrate η, angepasst werden. Grundlage für den BP-Algorithmus bildet die Hebbsche Lernregel:

$$\begin{aligned} \Delta w_\mathrm{ij} &\sim \eta \sigma_\mathrm{i} \sigma_\mathrm{j} \\ \Delta w_\mathrm{ij} &= -\eta \frac{\delta L}{\delta w_\mathrm{ij}} \end{aligned} \tag{A.2.6}$$

Diese Lernrate, ein Modulationsfaktor für Gewichtsänderungen, muss sorgfältig gewählt werden, um eine angemessene Trainingsgeschwindigkeit und die Vermeidung lokaler Minima zu gewährleisten. Die Methode des stufenweisen Reduzierens der Lernrate während des Trainings ist als Gradientenabstieg bekannt.

A.3 Grundlagen und Parametereinstellung der kooperativen Fahrfunktionen

A.3.1 Grundprinzip der modellprädiktiven Regelung

Im Folgenden wird das Grundprinzip der MPR kurz in einer allgemeinen Form dargestellt, bevor es im Kontext der vorliegenden Problemstellung konkretisiert wird.

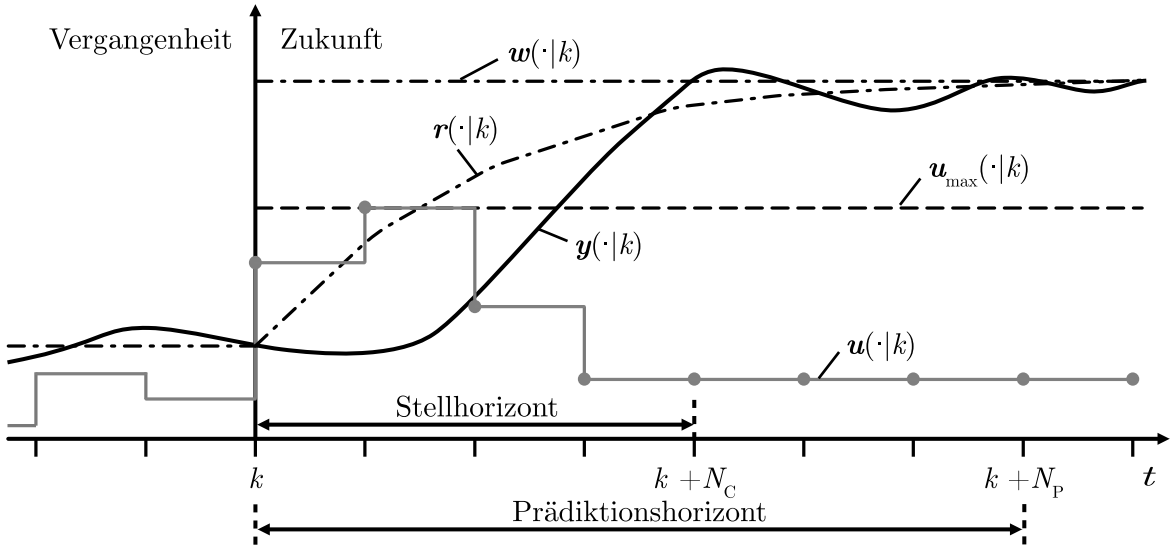

Abbildung A.3.1: Prinzip einer MPR nach [129]

Die MPR setzt ein geeignetes Prozessmodell ein, um das zukünftige Verhalten des Prozesses in Abhängigkeit von zukünftigen Stellgrößenverläufen zu prädizieren. In Abbildung A.3.1 ist ein zeitlicher Verlauf der Stellgröße $\boldsymbol{u}(\cdot|k)$, der Systemausgangsgröße $\boldsymbol{y}(\cdot|k)$ und des Sollwertverlaufs $\boldsymbol{w}(\cdot|k)$ vom Zeitpunkt k dargestellt. Dabei bezeichnet die Notation $\boldsymbol{a}(\cdot|k)$ den gesamten prädizierten Verlauf einer Größe $\boldsymbol{a}$, ausgehend vom Zeitpunkt k.
Ziel der MPR liegt darin, einen optimalen Stellgrößenverlauf zu ermitteln, der die Abweichung zwischen dem gewünschten Sollwertverlauf und dem prädizierten Verlauf der Regelgröße innerhalb des sogenannten Prädiktionshorizonts N_{p} unter Einhaltung aller Nebenbedingungen minimiert. Für nicht sprungfähige Systeme wird anstelle eines sprungförmigen Sollwertverlaufs eine zukünftige Referenztrajektorie $\boldsymbol{r}(\cdot|k)$ berechnet, die den dynamischen Übergang zum neuen Sollwert abbildet. Zur Reduzierung der zu optimierenden Parameter wird angenommen, dass sich $\boldsymbol{u}(\cdot|k)$ ab dem Zeitpunkt $k+N_{\mathrm{c}}$, dem sogenannten Stellhorizont, konstant verhält.

A.3.2 Parametereinstellung der kooperativen Fahrfunktionen

Die grundlegenden Parameter für die Simulationen zur Evaluierung des Energieeinsparpotentials im Folgefahrtszenario sind in Tabelle A.3.1 dargestellt.

Tabelle A.3.1: Simulationsparameter

Simulationsparameter	Zeichen	Werte
Prädiktionsmodell von Vorausfahrzeug Geschwindigkeit		LSTM
Stell- und Prädiktionshorizont	N_c, N_p	5s, 10s and 15s
Gewichtungsfaktor	$\boldsymbol{Q}$	$Q_\mathrm{s,KF} = 0{,}01$ $Q_\mathrm{d,FF} = 0.1$ $Q_\mathrm{v} = 0{,}5$ $Q_\mathrm{besch} = 0{,}05;\ 2{,}5;\ 5;\ 10;\ 12{,}5;\ 15;\ 17{,}5;\ 20;\ 25;\ 50$ $Q_\mathrm{verz} = 0{,}05;\ 2{,}5;\ 5;\ 10;\ 12{,}5;\ 15;\ 17{,}5;\ 20;\ 25;\ 50$
MPR Schrittweite	Δt_MPR	1s
Maximale Berechnungsiteration	n_iter	6000
Simulationsschrittweite	Δt_Sim	0.1s
Max. Min. und Referenzzeitabstand	$t_\mathrm{VFmax/min/ref}$	5s, 0.5s, 1s
Minimaler Abstand	d	4m
Fahrzeuglänge	l_Fzg	5m
Gewichtung der Schlupfvariale	q_ϵ	$q_{\epsilon,\mathrm{max}} = q_{\epsilon,\mathrm{min}} = 10^6$
Gesamtfahrzeuganzahl	$n_\mathrm{Fzg,ges}$	5
Initiale Position aller Fahrzeuge in m	$s_\mathrm{Fzg,i}$	$s_{VF} = 32{,}5$ $s_{KF} = 20$ $s_{FF1} = 15$ $s_{FF2} = 10$ $s_{FF3} = 5$ $s_{FF4} = 0$

Nachwort

光阴荏苒，转瞬至此。

自儿时踏入学堂那一刻起，未曾想今日能执笔于此，记吾数载寒窗之历。此篇博士论文之完成，乃数载研学之结晶，亦为人生一段难忘之旅。回首求学之路，既有迷惘徘徊之时，亦有豁然开朗之刻。每一步虽多艰难，然于此历程中，愈加笃定吾心，坚吾志。

“路之远则行将至，事虽难则做必成。”每念及此，深感博士求学如孤行远路。吾时而醉心学术，迷于探索未知之乐；时而踯躅不前，苦于解题无门之痛。然所幸道途不孤，师长之教诲，亲友之扶持，使吾于低谷中得以重拾信心，于无数深夜中仍见微光。

博士之路，既是学术之探求，亦为人生之砥砺。数载修行，教吾以坚忍，悟吾以感恩。人生百年，吾道不孤。论文虽已告一段落，然求索之志未曾止步。未来之路，愿秉赤诚之心，承“上下而求索”之志，为学界增添微光，为社会谋得福祉。

谨以此书献吾师长，谢其教导；献吾同仁，谢其相助；献吾家人，谢其厚恩。

此刻，非吾一人之荣耀，而众人之共勉也。

2025 春分，于亚琛，　　小楠执笔