

115

Karlsruher Schriftenreihe
Fahrzeugsystemtechnik

Tobias Sebastian Straub

Flottendatenbasierte physikalische Routenenergiebedarfsprognose



Scientific
Publishing

Tobias Sebastian Straub

**Flottendatenbasierte physikalische
Routenenergiebedarfsprognose**

**Karlsruher Schriftenreihe Fahrzeugsystemtechnik
Band 115**

Herausgeber

FAST Institut für Fahrzeugsystemtechnik

Prof. Dr.-Ing. Martin Cichon

Prof. Dr. rer. nat. Frank Gauterin

Prof. Dr.-Ing. Marcus Geimer

Prof. Dr.-Ing. Frank Henning

Prof. Dr.-Ing. Luise Kärger

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

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

Flottendatenbasierte physikalische Routenenergiebedarfsprognose

von
Tobias Sebastian Straub

Karlsruher Institut für Technologie
Institut für Fahrzeugsystemtechnik

Flottendatenbasierte physikalische Routenenergiebedarfsprognose

Zur Erlangung des akademischen Grades eines Doktors der Ingenieurwissenschaften (Dr.-Ing.) von der KIT-Fakultät für Maschinenbau des Karlsruher Instituts für Technologie (KIT) genehmigte Dissertation

von Tobias Sebastian Straub, M.Sc.

Tag der mündlichen Prüfung: 9. Januar 2024

Erster Gutachter: Prof. Dr. rer. nat. Frank Gauterin

Zweiter Gutachter: Prof. Dr. Ing. André Casal Kulzer

Impressum



Scientific
Publishing

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

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

www.ksp.kit.edu



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



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

Print on Demand 2024 – Gedruckt auf FSC-zertifiziertem Papier

ISSN 1869-6058

ISBN 978-3-7315-1348-3

DOI 10.5445/KSP/1000168810

Kurzfassung

Thema dieser Arbeit ist die Entwicklung einer präzisen Prognose des Energiebedarfs eines Elektrofahrzeuges entlang geplanter Routen. Diese Verbrauchsinformation ist wichtig für zuverlässige Reichweitenprognosen und weitere energetisch planende Anwendungen, wie z. B. eine Ladestoppplanung auf Langstreckenfahrten. Diese erleichtern den Alltag im Elektrofahrzeug. Mit dieser erhöhten Nutzerfreundlichkeit sinken Reichweitenängste, welche potenziell das Interesse an Elektrofahrzeugen hemmen. Damit stützen energetisch planende Anwendungen das Kaufinteresse an lokal emissionsfreien Elektrofahrzeugen. Dies hilft Regierungen und Staatenbünden, ihren Klimazielen für den Individualverkehrssektor näher zu kommen.

Um auf die Klimaziele mit energetisch planenden Funktionen hinarbeiten, ist entlang geplanter Strecken eine präzise, fahrtspezifische Energiebedarfsprognose unabdingbar, welche relevante Einflüsse separat quantifiziert. Nach der Identifikation solcher Einflüsse von Fahrzeug, Strecke und Fahrprofil, beschreibt diese Arbeit deren nachvollziehbare und übertragbare Modellierung. Für das physikalische Fahrzeugmodell lernt eine Fahrwiderstandsschätzung energetische Einflüsse an und korrigiert diese basierend auf einer Wetterprognose entlang der Strecke. Welchen Einfluss die Strecke und der Verkehr dabei auf das Fahrerverhalten haben, modelliert eine neuartige Fahrprofilprognose. Diese Prognose nutzt Flottendaten zu Geschwindigkeit und insbesondere zur Dynamik. Deren Einfluss auf die Energieflüsse beim Fahren und Rekuperieren erfassen dabei nur fünf Parameter. Ergänzt um Echtzeitverkehrsinformation ist diese Energiebedarfsprognose also strecken-, fahrer- und fahrtspezifisch.

Die Beurteilung der Genauigkeit dieses Prognoseansatzes in verschiedenen Varianten und im Vergleich mit Literaturmodellen stützt sich auf über 12000 km an Testfahrtstrecke. Entlang deren Strecken liegen in Summe 30 Millionen Kilometer an Flotten-Fahrdaten vor. Mit diesen Daten ist die genaueste Variante der flottendatengestützten physikalischen Energiebedarfsprognose absolut $12,5 \pm 2,6$ % genau und damit mindestens 18,4 % genauer als die gegenübergestellten Prognosemodelle aus der Literatur.

Dementsprechend kann die vorgestellte Energieprognose präzise und zuverlässige Information für energetisch planende Anwendungen bereitstellen. Beispiele der Anwendungen zeigt diese Arbeit abschließend anhand einer Reichweitenprognose sowie einer zeitlichen Routenoptimierung, welche die Stellhebel der Ladestoppplanung und der Geschwindigkeit damit zuverlässiger nutzen kann. Über solche Anwendungen soll diese Energiebedarfsprognose die Akzeptanz und das Vertrauen in die individuelle elektrische Mobilität stärken.

Abstract

Fleet Data based Route- Energy Demand Prediction

The subject of this work is the development of a precise forecast of the energy demand of an electric vehicle along planned routes. This consumption information is important for reliable range predictions and other energetically planning applications, such as charging stop planning on long-distance trips. These ease the daily routine in electric vehicles. This enhanced user-friendliness reduces range anxiety, which potentially inhibits interest in an electric vehicle. Thus, energetically planning applications increase the interest in buying locally emission-free electric vehicles. This helps international governments to get closer to their climate targets for the individual transport sector.

To work towards the climate goals using energy planning functions, a precise, trip-specific energy demand prediction along planned routes is indispensable, which separately quantifies relevant influences. Based on the identification of such influences of vehicle, route and driving profile, this work describes their verifiable and transferable modeling. In the physical vehicle model, a driving resistance estimation learns energetic influences and corrects them based on a weather forecast along the route. The route and traffic influence on driver behavior are modeled by a novel driving profile prediction. This forecast uses fleet data on speed and, in particular, dynamics. Their influence on the energy flows during driving and recuperation is captured by just five parameters. Augmented by real-time traffic information, this energy demand forecast is thus route-, driver- and trip-specific.

The assessment of the accuracy of this prediction approach in different configurations and in comparison, with literature models is based on more than 12000 km of test drives. Along their routes, a total of 30 million kilometers of fleet driving data are available. According to these data, the most accurate variant of the fleet data-based physical energy demand forecast is $12.5 \pm 2.6\%$ accurate

in absolute terms and thus at least 18.4% more precise than the compared forecast models from the literature.

Accordingly, the presented energy forecast can provide precise and reliable information for energetically planning applications. Finally, this work shows examples of applications in terms of a range prediction as well as a temporal route optimization, which can use the levers of charge stop planning and speed more reliably with it. Via such applications, this energy demand prediction should foster the acceptance and confidence in individual electric mobility.

Danksagung

Diese Dissertation entstand im Rahmen einer Kooperation des Karlsruher Instituts für Technologie (KIT) und einem Vorentwicklungsprojekt der Bayerische Motoren Werke AG (BMW), welches meine Forschung finanzierte.

Als erstes gilt mein Dank Prof. Dr. Frank Gauterin, meinem Doktorvater und Hausherrn meiner wissenschaftlichen Heimat dem Teilinstitut Fahrzeugtechnik des Instituts für Fahrzeugsystemtechnik des KITs. Ich möchte Ihm für das entgegengebrachte Vertrauen bei der Bearbeitung außerhalb des Instituts, die Betreuung, die konstruktiven Diskussionen bei regelmäßigen Meilensteintreffen sowie die Übernahme des Erst-Gutachtens danken. Für die freundliche Erstellung des Zweit-Gutachtens möchte ich Prof. Dr. André Casal Kulzer von der Universität Stuttgart danken. Ausgesprochen dankbar bin ich auch Dr. Michael Frey für die intensiven und wertvollen Diskussionen sowie viele Hinweise zur wissenschaftlichen Förderung meiner Arbeit am KIT. Mein persönlicher Dank gilt zudem allen Institutsmitarbeitenden, welche mich als reisenden Doktoranden offen aufnahmen. Sie ermöglichten es mir mich am Institut heimisch zu fühlen, sei es durch wissenschaftliche oder persönliche Treffen z. B. an der Boulderwand.

Meine Arbeit bei BMW war zudem geprägt von einer internen Kooperation zwischen den Abteilungen EG-631 Efficient Dynamics Kundenfunktionen und DE-301 für Datenanalyse und Analytics. Zunächst möchte ich den Kolleginnen und Kollegen bei EG-631 danken, für die offene, bereichernde Arbeitsumgebung und tolle Team-Erlebnisse. Dabei gilt mein besonders herzlicher Dank meinem BMW-Betreuer Harald Hofmeier, der mit seiner Vorarbeit das Vorentwicklungsprojekt ermöglichte und in zahllosen tiefen fachlichen Gesprächen meine Forschung, mich persönlich und meinen weiteren beruflichen Werdegang sehr bereicherte. Meinem Teamleiter Dr. Adrian Röth möchte ich für die gezielten wertigen Denkanstöße und seine Unterstützung danken. In seinem Energiemanagement Team fand ich die richtigen Fachspezialisten für Hilfe bei besonderen Herausforderungen und eine gute Heimat für die Studierenden, die Ihre Abschlussarbeit im Themengebiet meiner Dissertation ver-

fassten. So möchte ich Sebastian Baudisch, Martin Büchner, Dr. Simone Fuchs, Martin Kiener, Gregor Neumeier, Ivan Rumencovic, Edvards Traskovskis, Mark van Gelikum und Mattia Venditti danken. Darunter besonders hervorheben möchte ich Mandy Nagy, welche nicht nur eine hervorragende Abschlussarbeit verfasste, sondern auch den anstrengenden Weg zu einem gemeinsamen Journal Paper mit mir ging. Neben der Veröffentlichung eines weiteren Journal Papers ermöglichte mir die bereichernde Zusammenarbeit mit Maximilian Mertens (geb. Cussigh) auch eine Konferenz am Küchentisch und viele wertige Gespräche über all die kleinen und großen Dinge in und um ein Promotionsvorhaben. Zuletzt bei BMW aber nicht weniger möchte ich von DE-301 Dr. Thomas Schutzmeier und Dr. Maxim Sidorov für die Möglichkeit und Hilfe danken, die mir selbst auch mit Abschlussarbeiten und Paper-Veröffentlichungen ermöglichten in die Big-Data-Welt einzutauchen. Darüber hinaus bin ich allen Freunden in München für all die Boulder-, Schwimm-, Fahrrad-, Spiele-, Gesprächs-, Koch- und Wanderrunden dankbar, die mir tolle Erlebnisse, mentalen Ausgleich und wertvolle Freundschaften schenkten.

Für all dies lege meine Familie, allen voran meine Eltern Hildegunde und Maximilian Straub, den Grundstein mit all Ihrer hingebungsvollen Unterstützung nicht zuletzt während meines Studiums.

Zuletzt und dafür umso mehr: Danke aus tiefstem Herzen meiner baldigen Frau Dr. Constanze Vetter. Die wunderbare und angenehme Zeit mit Dir half und hilft mir immer wieder zu entspannen. Du warst und bist auch in den zehrenden Zeiten, wie während dieser Arbeit, meine seelische Stütze und Heimat.

München, Januar 2024

Tobias Straub

Vorwort des Herausgebers

Die Fahrzeugtechnik ist kontinuierlich Veränderungen unterworfen. Klimawandel, die Verknappung einiger für Fahrzeugbau und –betrieb benötigter Rohstoffe, globaler Wettbewerb, gesellschaftlicher Wandel und das rapide Wachstum großer Städte erfordern neue Mobilitätslösungen, die vielfach eine Neudefinition des Fahrzeugs erforderlich machen. Die Forderungen nach Steigerung der Energieeffizienz, Emissionsreduktion, erhöhter Fahr- und Arbeitssicherheit, Benutzerfreundlichkeit und angemessenen Kosten sowie die Möglichkeiten der Digitalisierung und Vernetzung finden ihre Antworten nicht aus der singulären Verbesserung einzelner technischer Elemente, sondern benötigen Systemverständnis und eine domänenübergreifende Optimierung der Lösungen.

Hierzu will die Karlsruher Schriftenreihe für Fahrzeugsystemtechnik einen Beitrag leisten. Für die Fahrzeuggattungen Pkw, Nfz, Mobile Arbeitsmaschinen und Bahnfahrzeuge werden Forschungsarbeiten vorgestellt, die Fahrzeugsystemtechnik auf vier Ebenen beleuchten: das Fahrzeug als komplexes, digitalisiertes mechatronisches System, die Mensch-Fahrzeug-Interaktion, das Fahrzeug in Verkehr und Infrastruktur sowie das Fahrzeug in Gesellschaft und Umwelt.

Batterieelektrisch angetriebene Fahrzeuge sind aufgrund nur eingeschränkt verfügbarer Energie und langer Ladezeiten bei weiten Fahrstrecken auf eine genaue Reichweitenprognose angewiesen. Eine große Anzahl von Einflussgrößen auf den Energiebedarf macht dies zu einer anspruchsvollen Aufgabe.

Die vorliegende Arbeit quantifiziert separat die Einflüsse des Antriebssystems, der Klimatisierung und sonstiger Nebenverbraucher, der Fahrwiderstände, der Strecke, der Witterung, des Verkehrs und des Fahrstils und erlaubt damit einen differenzierten Blick auf deren Relevanz für die Vorhersage des Energiebedarfs bei langen Fahrten. Der vorgeschlagene lernfähige Ansatz zur Reichweitenprognose trennt die Einflüsse von Fahrzeug und Strecke, liefert eine detaillierte streckenbezogene Verbrauchskarte, ermöglicht eine einfache

Anwendung auf verschiedene Fahrzeugtypen, lernt das Fahrerverhalten und berücksichtigt Verkehr und Witterung. Die erreichte Vorhersagegenauigkeit übertrifft die Präzision bislang bekannter Prognosemodelle.

Frank Gauterin

im Januar 2024

Inhaltsverzeichnis

Kurzfassung	i
Abstract	iii
Danksagung	v
Vorwort des Herausgebers	vii
Abbildungsverzeichnis	xiii
Tabellenverzeichnis	xvii
Abkürzungsverzeichnis.....	xix
Symbolverzeichnis	xxi
1 Einleitung	1
1.1 Motivation	1
1.2 Zielsetzung.....	2
1.3 Struktur der Arbeit.....	3
2 Grundlagen und Stand der Technik und Wissenschaft.....	7
2.1 Energiebedarf des Elektrofahrzeuges	7
2.1.1 Fahrwiderstände	8
2.1.2 Fahrzeugsysteme	15
2.1.3 Betrachtetes System.....	22
2.2 Prognosemodelle des Routenenergiebedarfs	23
2.2.1 Modellüberblick	23
2.2.2 Fahrzeugeigenschaften	32
2.2.3 Nebenverbraucher.....	34
2.2.4 Fahrprofil.....	35
2.3 Forschungsfragen.....	36
3 Sensitivitäten im Energiebedarf	39
3.1 Einflussgrößen	40
3.2 Energiebedarfsberechnung verschiedener Fahrprofilatentypen	42

3.2.1	Kontinuierlich.....	44
3.2.2	Quasistationär.....	44
3.3	Datengrundlage.....	46
3.4	Parametersensitivitäten.....	48
3.5	Identifikation Parameterrelevanz.....	50
4	Routenenergiebedarfsprognose.....	53
4.1	Anforderungen.....	53
4.2	Konzept.....	55
4.3	Trennung fahrzeug- und streckenspezifischer Parameter.....	57
4.4	Bewertungsmethodik.....	62
4.4.1	Vorgehen Ausprägungsdefinition.....	62
4.4.2	Fehlermaß Genauigkeitsanalyse.....	63
4.4.3	Vorgehen Aufwandsanalyse.....	66
4.4.4	Datengrundlage.....	66
5	Fahrzeugparameterbestimmung.....	69
5.1	Antriebsmodell.....	69
5.1.1	Fahrwiderstand.....	69
5.1.2	Effizienz.....	80
5.1.3	Ergebnis.....	88
5.1.4	Fazit.....	90
5.2	Nebenverbraucher.....	91
5.2.1	Innenraumtemperierung.....	91
5.2.2	Niedervoltssystem.....	94
6	Fahrprofilprognose.....	95
6.1	Flottenverhalten.....	95
6.1.1	Fahrprofildaten.....	95
6.1.2	Methodik.....	96
6.1.3	Herausforderungen bei der Umsetzung.....	100
6.1.4	Fazit.....	105
6.2	Fahrerverhalten.....	106
6.2.1	Fahrermodell.....	107
6.2.2	Einbindung Verkehrsinformation.....	111
6.2.3	Ergebnis.....	114

6.2.4	Fazit.....	117
7	Bewertung Routenenergiebedarfsprognose.....	119
7.1	Übersicht Teilmodelle	119
7.2	Modellvergleich.....	122
7.3	Umsetzungsempfehlungen.....	127
8	Anwendungen.....	129
8.1	Energie-Kartenlayer.....	129
8.2	Reichweitenberechnung.....	130
8.3	Routingfunktion für batterieelektrische Fahrzeuge.....	133
9	Zusammenfassung und Ausblick.....	137
	Veröffentlichungen.....	141
	Betreute Abschlussarbeiten	143
	Literaturverzeichnis.....	145
A	Anhang.....	165
A.1	Aufbau digitale Karte	165
A.2	Wetterprognose.....	166

Abbildungsverzeichnis

Abb. 1.1:	Struktur der Arbeit	5
Abb. 2.1:	Fahrwiderstände im Fahrbetrieb.....	9
Abb. 2.2:	Ursache des Rollwiderstands	11
Abb. 2.3:	Fahrzeugsysteme und deren Energiebedarf sowie Antriebsmomente bzw. -kräfte	15
Abb. 3.1:	Leistungsbedarf der Temperierung bezogen auf Minimalwert.....	41
Abb. 3.2:	Energiebedarfsänderung durch Einflüsse im Straßenbetrieb	49
Abb. 4.1:	Modellstruktur.....	56
Abb. 4.2:	Beispielhafte Darstellung einer Fehlerauswertung.....	65
Abb. 4.3:	Karte der Versuchsfahrten und deren Streckenanteile nach Straßentyp.....	67
Abb. 4.4:	Längen der Versuchsfahrten.....	67
Abb. 5.1:	Qualität verschiedener Algorithmen zur Fahrwiderstandsschätzung	72
Abb. 5.2:	Bewertung zweier Konvergenzerkennungen der Fahrwiderstandsschätzung bewertet ab Konvergenzzeitpunkt mit (unten) MEDPE (oben) MEDAPE	77
Abb. 5.3:	Bewertung der Fahrwiderstandsmodelle.....	78
Abb. 5.4:	Bewertung der Fahrwiderstandsmodelle für verschiedene Validierungsgruppen für (2) und (3) ab Schätzerkonvergenz	79
Abb. 5.5:	Bewertung zweier Konvergenzerkennungen der Effizienzschätzung	86
Abb. 5.6:	Bewertung verschiedener Effizienzmodelle.....	87

Abb. 5.7:	Antriebsmodellbewertung basierend auf Soll-Fahrprofil mit MEDPE (oben) und MEDAPE (unten).....	89
Abb. 5.8:	Kennfeld der Temperierungsleistung nach.....	92
Abb. 5.9:	Bewertung Innenraumtemperierungsverbrauchsprognose basierend auf Soll-Fahrprofil für verschiedene Inputs auf Temperierungs- (oben) und Gesamtverbrauchsebene (unten).....	93
Abb. 5.10:	Bewertung Niedervoltverbrauchsprognose basierend auf Soll-Fahrprofil.....	94
Abb. 6.1:	Flottendatenbasierte Fahrprofilprognose der Energiebedarfsprognose	98
Abb. 6.2:	Beispielhafte Energetische Fahrprofil-Kartenattributsverteilungen (FPKAV) auf einem Autobahnabschnitt	99
Abb. 6.3:	Verfügbarkeit von zeit- und richtungsspezifischen FPKAV zu verschiedenen Zeiten	102
Abb. 6.4:	Bewertung im MEDPE der stufenweisen Überführung von Datenergänzung mit verwandten Daten zur Regressionsergänzung.....	104
Abb. 6.5:	Morphologischer Kasten der Aggregation des Fahrerverhaltens.....	109
Abb. 6.6:	Fahrermodellbewertung ohne RTTI anhand MEDPE (oben) und MEDAPE (mittig) in Klemmenenergieverbrauch sowie (unten) MEDPE in mittlerer Geschwindigkeit.....	114
Abb. 6.7:	Gegenüberstellung Detail-Fahrermodell mit und ohne Verkehrsberücksichtigung in MEDPE (oben) und (unten) MEDAPE bezogen auf Klemmenenergieverbrauch	115
Abb. 6.8:	Einfluss Diskretisierung entsprechend Karte oder zusätzlichen 50 m Sublinks	117

Abb. 7.1:	Morphologischer Kasten verschiedener Energiebedarfsprognoseausprägungen	120
Abb. 7.2:	Relative Rechenzeit der Konzepte bezogen auf Maximalwert	123
Abb. 7.3:	MEDPE (oben) und MEDAPE (unten) verschiedener Energieprognoseausprägungen.....	125
Abb. 7.4:	MEDAPE verschiedener Energieprognoseausprägungen nach Validierungsgruppen	128
Abb. 8.1:	Energie-Kartenlayer	130
Abb. 8.2:	MEDPE (oben) und MEDAPE (unten) der Reichweitenberechnung mit verschiedenen Energieprognosemodellen	132
Abb. 8.3:	Struktur der zeitoptimalen Fahr-& Ladestrategieermittlung.....	135
Abb. 9.1:	Beispiel eines gerichteten Graphennetzwerkes	165

Tabellenverzeichnis

Tab. 2.1:	Überblick der Literatur zu Energiebedarfsprognosemodellen	24
Tab. 3.1:	Analysierte Bandbreiten der Einflüsse auf den Energiebedarf	43
Tab. 3.2:	Fahrprofildaten der Dynamikkollektive	46
Tab. 4.1:	Energetische Fahrprofil-Kartenattribute (FPKA).....	61
Tab. 7.1:	Umsetzungsempfehlungen	128
Tab. 8.1:	Optimierungsergebnisse mit kennfeldbasierter und Abweichungen dazu mit der physikalischen Energiebedarfsprognose	136

Abkürzungsverzeichnis

Abkürzung	Bedeutung
A. d. A.	Anmerkung des Autors
BMW	Bayerische Motorenwerke
FAST	Fahrzeugsystemtechnikinstitut
FPKA	Energetische Fahrprofil-Kartenattribute
FPKAV	Energetische Fahrprofil-Kartenattributsverteilung
GPS	Global Positioning System
GLONASS	Global Navigation Satellite System
GTLS	Generalized Total Least Square
HVB	Hochvoltbatterie
IV	Instrument Variablen
KF	Kalman-Filter
KIT	Karlsruher Institut für Technologie
mf	Multiple Vergessensfaktoren (eng.: multiple forgetting)
M	M-Schätzer für Regulierung
PKS	Polynomische Kalman-Glättung (eng.: Polynomial Kalman Smoother)
PTC	Positiver Temperaturkoeffizient (eng.: Positive Temperature Coefficient)
LMR	Nach Levenberg-Marquardt regulierter Schätzer
Roder RLS	Rekursive kleinste Quadrate (eng.: least squares) Regression (zweites R in Schätzerabkürzungen)
RTTI	Echtzeitverkehrsinformation (eng.: Real Time Traffic Information)
SG	Stenlund-Gustafsson Regulierung
SOC	Ladezustand (eng.: State of Charge)
USA	Vereinigte Staaten von Amerika (eng.: United States of America)

Symbolverzeichnis

Zum Nachschlagen von Symbolen und Notationen sind diese in der folgenden Arbeit mit der Erklärung hier verlinkt.

Symbol	Einheit	Bezeichnung
a	$\left(\frac{m}{s^2}\right)$	Beschleunigung
A	(m^2)	Fahrzeugstirnfläche
B	$\left(T = \frac{kg}{s^2 \cdot A}\right)$	Magnetische Flussdichte
c	(1)	Koeffizient mit Einheit (1)
$c_{RW,\vartheta}$	$\left(\frac{1}{K}\right)$	Rollwiderstandstemperaturkorrekturfaktor
$c_{VL,H}$	$\left(\left(\frac{A}{kg}\right)^k \cdot (s^2)^{k-1}\right)$	Koeffizient zur Hystereseverlustberechnung
d	(m)	Dicke
e	(1)	Drehmassenzuschlagsfaktor
E	$\left(W_S = \frac{kg \cdot m^2}{s^2}\right)$	Energiebedarf
f	$\left(\frac{1}{s}\right)$	Frequenz
F	(%)	Kraft
g	$\left(\frac{m}{s^2}\right)$	Erdbeschleunigung
φ	(-)	Gerichteter Graph
i	(1)	Getriebeübersetzung von Bauteile mit Index 1 mit Drehzahl $\omega_{Index\ 1}$ auf Drehzahl $\omega_{Index\ 2}$ des Bauteiles mit Index 2 (z. B. $i_{M,RD} = \frac{\omega_M}{\omega_{RD}}$ ist die Übersetzung vom Elektromotor zum Rad)
I	(A)	Elektrischer Strom

Symbol	Einheit	Bezeichnung
IB	$\left(\frac{m}{s^2} \cdot \frac{m}{m}\right)$	Integrale Beschleunigung
IBR	$\left(\frac{m}{s^2} \cdot \frac{m}{m}\right)$	Integrale Beschleunigung in Rekuperationsphasen (eines der FPKA)
IBV	$\left(\frac{m}{s^2} \cdot \frac{m}{m}\right)$	Integrale Beschleunigung in Vortriebsphasen (eines der FPKA)
IQG	$\left(\sqrt{\frac{m^2}{s^2}} \cdot \frac{m}{m}\right)$	Integrale quadratische Geschwindigkeit (eines der FPKA)
IQGR	$\left(\sqrt{\frac{m^2}{s^2}} \cdot \frac{m}{m}\right)$	Integrale quadratische Geschwindigkeit in Rekuperationsphasen (eines der FPKA)
IQGV	$\left(\sqrt{\frac{m^2}{s^2}} \cdot \frac{m}{m}\right)$	Integrale quadratische Geschwindigkeit in Vortriebsphasen (eines der FPKA)
IQR	Wie Indexvariable, wenn definiert	Interquartilabstand (eng: inter quartile range): Innere 50% einer geordneten Stichprobe
<i>j</i>	(1)	Diskreter Zähler der Links einer Route
<i>m</i>	(kg)	Masse
MEDAPE	(%)	Median der absoluten prozentualen Fehler (eng.: median absolute percentage error).
MEDPE	(%)	Median prozentualer Fehler (eng.: median percentage error).
MG	$\left(\frac{m}{s}\right)$	Mittlere Geschwindigkeit (eines der FPKA)
<i>n</i>	(1)	Stichprobengröße
<i>NKE</i>	$\left(\frac{m}{s^2}\right)$	Negative kinetische Energieverbrauchsrate normiert auf Weg und Gewicht [1]
<i>p</i>	$\left(\frac{N}{m^2} = \frac{kg}{s^2 \cdot m}\right)$	Druck
<i>p</i>	(-)	Parametervektor der Fahrwiderstandsgleichung
<i>P</i>	$\left(W = \frac{kg \cdot m^2}{s^3}\right)$	Leistung

Symbol	Einheit	Bezeichnung
PKE	$\left(\frac{m}{s^2}\right)$	Positive kinetische Energieverbrauchsrate normiert auf Weg und Gewicht [1]
PE	(%)	Prozentualer Fehler (eng.: percentage error)
Q1	Wie Indexvariable, wenn definiert	Erstes Quartil bzw. 25% Perzentilwert
R	$\left(\Omega = \frac{kg \cdot m^2}{s^3 \cdot A^2}\right)$	Elektrischer Widerstand
R_L	$\left(\frac{N}{m^2}\right)$	Spezifische Gaskonstante der Luft
Reichweite	(km)	Reichweite mit übrigem Energieinhalt im HVB
r	(m)	Radius
\mathbf{r}	(–)	Routenvektor der Strecken- bzw. Routeneinflüsse
s	(m)	Weg
Streckenreichweite (km)		Reichweite mit übrigem Energieinhalt im HVB abzüglich verbleibende Reichweite[z] am Routenziel
t	(s)	Zeit
T	(Nm)	Drehmoment
u	(%)	Perzentil bzw. Quantil
U	$\left(V = \frac{kg \cdot m^2}{s^3 \cdot A}\right)$	Elektrische Spannung
v	$\left(\frac{m}{s}\right)$	Geschwindigkeit
V	(m^3)	Volumen
\mathbf{V}	(–)	Knoten oder Ecken
W	(%)	Wahrscheinlichkeitsverteilungsfunktion
x	(m)	Wegposition entlang einer Route
X_0	(W)	Koeffizient Effizienzschätzung für Verluste durch Nullmomentregelung.
X_H	$\left(\frac{s^2}{kg \cdot m^2}\right)$	Koeffizient Effizienzschätzung für Verluste durch magnetische Hysterese

Symbol	Einheit	Bezeichnung
X_S	$\left(\frac{1}{s}\right)$	Koeffizient Effizienzschätzung für Verluste durch Inverterschalten
X_Ω	$\left(\frac{s}{kg \cdot m^2}\right)$	Koeffizient Effizienzschätzung für Ohm'sche Verluste
y	(1)	Wert der Zufallsvariable Y
Y	Wie Indexvariable, wenn definiert	Zufallsvariable bzw. Stichprobenwert falls Zählindex angegeben
z	(1)	Anzahl der Links einer Route
α	(°)	Steigungswinkel
ε	(-)	Kante
η	(1)	Wirkungsgrad
ϑ	(°C)	Temperatur
Θ	$(kg \cdot m^2)$	Trägheitsmoment des Bauteiles mit Index 1 bezogen auf Drehzahl $\omega_{Index\ 2}$ des Bauteiles mit Index 2
ρ	$\left(\frac{kg}{m^3}\right)$	Dichte
ϱ	$(\Omega \cdot m)$	Spezifischer elektrischer Widerstand
τ	(°)	Anströmwinkel
ω	$\left(\frac{1}{s}\right)$	Drehzahl bzw. Drehgeschwindigkeit

Index Bezeichnung bezogen auf:

0	Bezugsgröße
A	Antrieb
B	Beschleunigungswiderstand
F	Fahrer
Fe	Eisen im Elektromotor
FW	Gesamtfahrwiderstand
FZ	Fahrzeug
g	Grenzwert zwischen Vortrieb-/Rekuperationsphasen

Index Bezeichnung bezogen auf:

<i>G</i>	Fahrzeuggewicht
<i>H</i>	Magnetische Hysterese
HVB	Klemme Hochvoltbatterie
<i>i</i>	Zählindex
<i>k</i>	Zählindex
<i>L</i>	Luftwiderstand
<i>LV</i>	Niedervolt 12 V Fahrzeugnetz (eng.: low voltage)
<i>m</i>	Modifizierter FPKA Wert
<i>M</i>	Elektrischer Motor
<i>N</i>	Normal bzw. senkrecht auf die Aufstandsfläche
<i>NV</i>	Nebenverbraucher
<i>o</i>	Originaler bzw. unveränderter FPKA Wert
<i>O</i>	Wert Obergrenze
<i>pro</i>	prognostizierter Wert (nur angegeben falls verwechselbar)
<i>R</i>	Rekuperation
<i>rel</i>	Relativ zwischen Luft und Fahrzeugoberfläche
<i>RD</i>	Rad
RTTI	Aus Echtzeitverkehrsinformation
<i>RW</i>	Rollwiderstand
<i>spez</i>	Spezifischer Wert bezogen auf Strecke, Einheit $\left(\cdot \frac{1}{m}\right)$. Z. B. E_{spez} in $\left(Ws \cdot \frac{1}{m} = \frac{kWh}{100 km} \frac{10^5}{3.6 \cdot 10^6}\right)$
<i>S</i>	Schalten der Halbleiterschalter im Inverter
<i>St</i>	Steigung
<i>T</i>	Temperierung Innenraum
<i>u</i>	Umgebung
<i>U</i>	Wert Untergrenze
<i>ver</i>	Verbleibender Wert, z. B. $E_{HVB,ver}$ verbleibender nutzbarer Energieinhalt der HVB
<i>V</i>	Vortrieb
<i>Vl</i>	Verlust
<i>W</i>	Wirbelströme in ferromagnetischen Teilen des Elektromotors
<i>Wind</i>	Wind

Index Bezeichnung bezogen auf:

x	x-Richtung bzw. Fahrzeugfahrtrichtung
κ	Anzahl Stützstellen diskrete Wahrscheinlichkeitsfunktion
ϑ	Temperatur
Ω	Ohm'scher Widerstand

Exponent Einheit Bezeichnung

k	(1)	Empirischer Exponent zur Hystereseverlustberechnung
-----	-----	---

Notation	Bedeutung
\dot{x}	Zeitliche Ableitung der Variablen x
\hat{x}	Erwartungswert der Variablen x
\bar{x}	Mittelwert der Variablen x
$\bar{\bar{x}}$	Median bzw. Wert des 50 % Perzentiles der Variablen x
\tilde{x}	Aus Stichproben empirisch ermittelter Zusammenhang x
$P[\text{Bedingung}]$	ist die Wahrscheinlichkeit des Zutreffens der Bedingung in eckigen Klammern. Z. B. $P[Y \leq y]$ ist die Wahrscheinlichkeit, dass y kleiner oder gleich einer aus der Zufallsvariablen Y genommenen Stichprobe ist.
$I[\text{Bedingung}]$	ist die Einheitsfunktion, die 1 ist, wenn die Bedingung zutrifft und sonst 0
$\theta(x)$	ist die Heaviside Stufenfunktion, die 1 ist, wenn $x \geq 0$ und sonst 0
<u> </u> <i>Übernommener Abschnitt:</i>	In der Forschung ist eine schnelle Veröffentlichung von Ergebnissen essenziell für den Austausch in der Wissenschaftsgemeinde. Diese Arbeit ist jedoch nicht eine kumulative Aneinanderreihung von Veröffentlichungen. Solch eine Aneinanderreihung wäre weniger flexibel als eine Monografie bezüglich einer

Notation	Bedeutung
<p>[Dieser übernommene Abschnitt ist zur Einheitlichkeit dieser Arbeit neuformatiert und übersetzt. xx]___</p>	<p>Neuordnung der Ergebnisse für eine verständliche Erklärungsstruktur. Der hier gewählte Mittelweg ist eine explizite Markierung übernommener Abschnitte. Ein solcher Abschnitt beginnt wie links gezeigt. Diese Abschnitte beinhalten eine Übersetzung des englischen Originaltextes ins Deutsche. Diese Abschnitte sind für die Einheitlichkeit der Darstellung in dieser Arbeit neu formatiert und enthalten Anpassungen in den verwendeten Symbolen.</p> <p>Am Ende eines solchen Abschnittes nach dem letzten Satz oder für Tabellen und Abbildungen alleinigt folgt in eckigen Klammern der Verweis auf die ursprüngliche Quelle des Inhaltes.</p>

1 Einleitung

1.1 Motivation

Die internationale Gesetzgebung fordert über die Jahre zunehmend eine Reduktion klimaerwärmender Treibhausgase [2–4]. Da elektrische Fahrzeuge lokal emissionsfrei fahren können, worauf die gesetzlichen Klimaziele für die Hersteller basieren, steigen im Bereich individueller Mobilität deren Verkaufszahlen [5; 6, S. 46]. Jedoch halten einige Faktoren potenziell Kaufende ab. So dauert ein kompletter Ladevorgang des Elektrofahrzeugs heute länger als das Volltanken mit Kraftstoff. Zudem kann man sein elektrisches Fahrzeug an zu wenigen Orten schnell aufladen, um seine Batteriekapazität optimal zu nutzen [7]. Angesichts dieser Gegensätzlichkeit von langer Ladezeit und unzureichender Ladeinfrastruktur entwickeln FahrerInnen Reichweitenangst [8], also die Angst davor, während der Fahrt mit einer leeren Batterie liegen zu bleiben [9]. Daher nutzen FahrerInnen aus Vorsicht bis zu 20 % der verfügbaren Batteriekapazität kaum [10]. Für diese Herausforderung sind größere Batterien ein Weg, der Unsicherheit durch eine zu spärliche Ladeinfrastruktur entgegenzuwirken [7, S. 357]. Jedoch ist dies nicht zuletzt wegen der hohen Kosten von über 100 \$ pro *kWh* [11] und des höheren Gewichts mit folgendem höheren Verbrauch und für die Reichweitenangst kontraproduktiver geringerer Reichweite wenig sinnvoll. Für den alternativen Ansatz der effizienteren Nutzung der installierten Energie zur Reduzierung der Reichweitenangst ist eine präzise Reichweitenvorhersage unerlässlich. So zeigen Fehlereinflussanalysen, dass eine um 8 Prozentpunkte genauere Reichweitenprognose im deutschen Streckenmittel 30 *kWh* weniger Reichweitenpuffer bei gleichen Ladezeiten auf Gesamtreisedauerebene ermöglichen kann [7, S. 357]. Auch eine Optimierung der Gesamtreisedauer mit den Stellhebeln der Ladepunkt- und Geschwindigkeitswahl hat insbesondere im heterogenen Ladeumfeld Potenzial [12]. Das ist möglich, da der Energiebedarf erheblich von der Reisegeschwindigkeit

abhängt und damit Anzahl sowie Ort der Ladestopps beeinflusst. Folglich benötigen diese und andere energetisch planende Anwendungen, um dem Fahrer zuverlässige Informationen bereitzustellen, eine präzise, alle Einflüsse berücksichtigende Energiebedarfsprognose für geplante Routen.

1.2 Zielsetzung

Für verschiedene energetisch planende Anwendungen soll diese Arbeit eine Prognose des Energiebedarfs entlang vorausliegender Strecken entwickeln, welche möglichst genau und lokal aufgelöst ist. Da sich nur über einen bekannten Streckenverlauf zuverlässig planen lässt, gilt die Annahme, dass eine Route z. B. durch aktive Zielführung bekannt ist. Die verschiedenen Anwendungen müssen entlang dieser Route möglichst zuverlässige Entscheidungen für (Betriebs-)Strategien fällen können. Als Grundlage für diese Strategien muss ein recheneffizientes Prognosemodell die relevanten Sensitivitäten genau und separat identifizieren und lokal aufgelöst quantifizieren. Hierbei sind eine Trennung und Modellierung entsprechend den physikalischen Zusammenhängen anzustreben, was folgende Vorteile hat:

- Nachvollziehbarkeit durch physikalisches Modell.
- Hohe Recheneffizienz durch analytische Modellbildung.
- Flexible Modellbildung durch Berücksichtigung von Einzeleinflüssen in energetisch planenden Anwendungen, welche die Prognose nutzen.
- Vermeidung von Mehrfachaufwand für Prognose und Datenspeicherbedarf durch Modellverallgemeinerung und Nutzbarkeit für verschiedene Antriebskonfigurationen und -typen.
- Sicherstellung großer Datenbasis von verschiedensten Fahrzeugen einer Flotte durch Übertragbarkeit.
- Nutzen für breite Nutzerbasis größer als erhöhter Aufwand durch umfangreichere Datenmenge.
- Möglichkeit von Prognosen für Antriebskonzepte mit wenig oder keinen Repräsentanten in Daten auf großer Datenbasis durch Übertragbarkeit.

Zusammengefasst ist das Ziel dieser Arbeit eine möglichst genaue physikalische Prognose des Energiebedarfes entlang einer Route, die Flottendaten nutzt sowie energetische Einflüsse rasch anlernt und dann separat entlang einer Strecke spezifisch für einen gegebenen Fahrer ausweist.

1.3 Struktur der Arbeit

Nach dem einleitenden Abschnitt oben zeigt Abb. 1.1 die Struktur dieser Arbeit im Überblick auf. Kapitel 2 erläutert zunächst die Grundlagen des Energiebedarfes eines Elektrofahrzeuges. Anschließend ist der Stand der Technik und Wissenschaft zur Prädiktion des Fahrzeugenergiebedarfes zusammengefasst. Ausgehend davon schließt Kapitel 2 mit der Definition der Forschungsfragen. Die in Kapitel 3 beschriebene Sensitivitätsanalyse des Energiebedarfes bildet die Grundlage für die Definition der Modellschwerpunkte. Auf Basis dieser Schwerpunkte und der benötigten Informationen der in 1.1 zusammengefassten energetisch planende Anwendungen erörtert Kapitel 4 zunächst die Anforderungen an eine Routenenergiebedarfsprognose. Der verbleibende Teil des Kapitels beschreibt die Herleitung des umgesetzten Konzeptes und wie dieses zu bewerten ist. Dabei ist die Basis des Konzeptes die Trennung des Fahrprofil- und Steigungseinflusses von den Fahrzeugeinflussparametern. Ausgehend von den Energieverbrauchern beschreibt Kapitel 5 die Fahrzeugparameterbestimmung. Dabei wird für jeden Teilaspekt getrennt auf die angewandte Methodik und die nötigen Untersuchungen eingegangen. Anschließend erläutert Kapitel 6 in ähnlicher Weise die Fahrprofilprognose basierend auf Flottendaten spezifisch für einen Fahrer. Die folgende Beurteilung und Umsetzungsempfehlung auf Gesamtmodellebene in Kapitel 7 führt mit dem übergreifenden Konzeptkapitel 4 die Teilaspekte des Modells aus Kapitel 5 und 6 zusammen. Anschließend zeigt Kapitel 8 beispielhafte Anwendungen. Abschließend fasst Kapitel 9 das Vorgehen zusammen und gibt einen Ausblick auf mögliche zukünftige Forschungsthemen.

Die oben beschriebenen Kapitel 4 und 6 enthalten wiederverwendete Abschnitte aus bereits veröffentlichten Forschungsergebnissen. Denn in der Forschung ist eine schnelle Veröffentlichung von Ergebnissen essenziell für den

Austausch in der Wissenschaftsgemeinde. Diese Arbeit ist jedoch nicht eine kumulative Aneinanderreihung von Veröffentlichungen. Dies wäre weniger flexibel als eine Monografie bezüglich einer Neuordnung der Ergebnisse für eine verständliche Erklärungsstruktur. Der hier gewählte Mittelweg ist eine explizite Markierung übernommener Abschnitte.

___ *Übernommener Abschnitt*: Ein solcher Abschnitt erscheint wie dieser. Diese Abschnitte beinhalten eine Übersetzung des englischen Originaltextes in deutsche Sprache. Diese Abschnitte sind für die Einheitlichkeit der Darstellung in dieser Arbeit neu formatiert und enthalten Anpassungen in den verwendeten Symbolen. Am Ende eines solchen Abschnittes folgt nach dem letzten Satz oder für Tabellen und Abbildungen alleinig in eckigen Klammern der Verweis auf die ursprüngliche Quelle des Inhaltes. [*Dieser übernommene Abschnitt ist zur Einheitlichkeit dieser Arbeit neuformatiert und übersetzt. XX*]___

2	Grundlagen und Stand der Technik und Wissenschaft
	Energiebedarf des Elektrofahrzeuges
	Prognosemodelle des Routenenergiebedarfs
	Forschungsfragen
3	Sensitivitäten im Energiebedarf
	Einflussgrößen
	Energiebedarfsrechnung verschiedener Fahrprofiltypen
	Datengrundlage
	Parametersensitivitäten
	Identifikation Parameterrelevanz
4	Routenenergiebedarfsprognose
	Anforderungen
	Konzept
	Trennung fahrzeug- und streckenspezifischer Parameter
	Bewertungsmethodik
5	Fahrzeugparameterbestimmung
	Antriebsmodell
	Nebenverbraucher
6	Fahrprofilprognose
	Flottenverhalten
	Fahrerverhalten
7	Bewertung Routenenergiebedarfsprognose
	Übersicht Teilmodelle
	Methodenvergleich
	Umsetzungsempfehlungen
8	Anwendungen
	Energie-Kartenlayer
	Reichweitenberechnung
	Routingfunktion für batterieelektrische Fahrzeuge
9	Zusammenfassung und Ausblick

Abb. 1.1: Struktur der Arbeit

2 Grundlagen und Stand der Technik und Wissenschaft

Dieses Kapitel erläutert zunächst die Ursachen und Abhängigkeiten des Energiebedarfes eines elektrischen Fahrzeuges in 2.1. Anschließend beschreibt 2.2, wie bereits bekannte Modelle diesen Energiebedarf vorhersagen. Darauf basierend legt 2.3 die Forschungsschwerpunkte innerhalb der identifizierten Forschungslücken fest.

2.1 Energiebedarf des Elektrofahrzeuges

Die während der Fahrt entlang einer Route wirkenden Fahrwiderstände bestimmen hauptsächlich den Energiebedarf eines Fahrzeuges [13, S. 13–14]. Das Kapitel 2.1.1 erläutert dazu die Fahrwiderstandskräfte im Detail. Den mechanischen Energiebedarf zum Überwinden der Fahrwiderstände stellt der elektrische Antriebsstrang an den Antriebsrädern bereit. Der Antriebsstrang bezieht dazu den elektrischen Antriebsstrangenergiebedarf aus der Hochvoltbatterie (HVB). Der Antriebsstrang kann auch elektrische Energie in die HVB zurückspeisen oder rekuperieren, z. B., wenn sich bei Bergabfahrt die Richtung der Fahrwiderstandssumme umdreht und mechanische Energie an den Antriebsrädern zur Verfügung steht. Bei diesen Umwandlungen zwischen elektrischer und mechanischer Energie geben die in 2.1.2 beschriebenen wirkungsgradbehafteten Antriebsstrangkomponenten auch Wärme ab. Das Abführen dieser Wärme sowie der Betrieb von Sicherheits- und Komfortsystemen bezieht bei Elektrofahrzeugen den elektrischen Nebenverbraucherenergiebedarf aus der HVB. Dies legt 2.1.2 ebenfalls dar. Abschließend erläutert 2.1.3 die Systemgrenzen für die Prognose des gesamten Routenenergiebedarfs eines Elektrofahrzeuges bestehend aus Nebenverbraucher- und Antriebsstrangenergiebedarf.

2.1.1 Fahrwiderstände

Die Gesamtfahrwiderstandskraft setzt sich entsprechend (2.1) aus der Summe von Rad- F_{RD} , Luft- F_L , Beschleunigungs- F_B und Steigungswiderstand F_{St} zusammen [13, S. 14; 14, S. 69]. Abb. 2.1 zeigt die vom Antrieb an den Antriebsrädern bereitgestellte Antriebskraft F_A , die der Summe an Fahrwiderstandskräften F_{FW} entgegenwirkt. Deren Kraftangriff am gezeigten Fahrzeug gilt für eine Fahrt mit der momentanen Geschwindigkeit v bei einer Beschleunigung a in Fahrzeuginnenrichtung auf einer Fahrbahn mit Steigung α .

$$F_{FW} = -F_A = F_{RD} + F_L + F_B + F_{St} \quad (2.1)$$

Der Energiebedarf zum Überwinden dieser Fahrwiderstandskräfte ist der mechanische Radenergiebedarf E_{RD} . Entsprechend (2.2) ergibt sich E_{RD} aus dem Wegintegral der Gesamtfahrwiderstandskraft F_{FW} [14, S. 73].

$$E_{RD} = \int F_{FW}(s) ds \quad (2.2)$$

Es gibt zwei Gruppen von Fahrwiderstandskräften, die am Fahrzeug angreifen. Einerseits die Kräfte, die zur Überwindung von Reibung wirken. Dazu gehören die Radwiderstandskraft F_{RD} und die Luftwiderstandskraft F_L . Diese überwinden die Rollreibung und die aerodynamische Reibung während der Fahrt. Diese dissipierenden Fahrwiderstandskräfte greifen am Fahrzeug immer entgegen der Fahrtrichtung an. Andererseits werden bei Überwindung des Beschleunigungs- F_B und des Steigungswiderstands F_{St} kinetische bzw. potenzielle Energie in der Fahrzeugmasse gespeichert. Nur diese Fahrwiderstandskräfte können über umgekehrte Beschleunigungs- F_B und Steigungswiderstände F_{St} kinetische bzw. potentielle Energie der Fahrzeugmasse in den Antriebsstrang zurückführen [13, S. 13–14].

Beschleunigungswiderstand

Der nur entsprechend der Längsbeschleunigung a bei beschleunigter, wie in Abb. 2.1 gezeigt, oder verzögerter Fahrt auftretende Beschleunigungswiderstand F_B ergibt sich nach (2.3). Diesen Widerstand verursachen die beschleunigte Fahrzeugmasse m_{FZ} und die Trägheit aller rotierenden Teile in Form

einer d'Alembert'schen Trägheitskraft. Dabei ist die Rotationsträgheit durch den Drehmassenzuschlagsfaktor e repräsentiert. Dieser Faktor berechnet sich nach (2.4) aus der Summe der Trägheitsmomente von allen Rädern $\Theta_{RD,RD}$ und des Antriebsstranges $\Theta_{A,M}$ im Verhältnis zur Fahrzeugmasse m_{FZ} . Wobei die Wirkung der Trägheitsmomente bezogen auf die translatorische Fahrzeugbewegung über die Getriebeübersetzung $i_{M,RD}$ und den dynamisch wirksamen Radradius r_{RD} erfolgt. [13, S. 17; 14, S. 68; 15, S. 156; 16, S. 104]

$$F_B = m_{FZ} \cdot e \cdot a \quad (2.3)$$

$$e = \frac{\Theta_{RD,RD} + i_{M,RD}^2 \cdot \Theta_{A,M}}{r_{RD}^2 \cdot m_{FZ}} + 1 \quad (2.4)$$




Abb. 2.1: Fahrwiderstände im Fahrbetrieb [nach 13, S. 14; 17, S. 13]

Steigungswiderstand

$$F_{St} = F_G \cdot \sin(\alpha) = m_{FZ} \cdot g \cdot \sin(\alpha) \quad (2.5)$$

Der Steigungswiderstand F_{St} ist der in Fahrzeuginnenrichtung wirkende Teil der Gewichtskraft F_G . Wie in Abb. 2.1 eingezeichnet, lässt sich dieser Anteil unter Berücksichtigung des Steigungswinkels α mit (2.5) ermitteln. Die Gewichtskraft berechnet sich dabei aus der translatorischen Fahrzeugmasse m und der Erdbeschleunigung g . [13, S. 16; 14, S. 67; 15, S. 155; 16, S. 103]

Rollwiderstand

Allgemein setzt sich der Radwiderstand F_{RD} neben dem dominierenden Rollwiderstand des Reifens aus Anteilen verursacht durch Fahrbahn, Schräglauf und Lagerreibung zusammen [14, S. 55]. Dies gilt insbesondere bei Geradeausfahrt auf trockener Fahrbahn. Dabei lässt sich für den Radwiderstand annehmen, dass der Anteil durch Verformung der Fahrbahn vernachlässigbar ist [14, S. 56]. Weiter ist der Schräglaufanteil wegen geringer eingestellter Spurrwinkel und bei geringer angenommener Querdynamik im Rahmen der Routenenergiebedarfsprognose vernachlässigbar. Schließlich betrachtet diese Arbeit den Anteil der Lagerreibung als Teil der Wirkungsgrade der Antriebsstrangkomponenten, wie in 2.1.2 beschrieben. Wie dargelegt, kann der Radwiderstand F_{RD} unter den angenommenen Normalbedingungen dem Rollwiderstand gleichgesetzt werden [18, S. 19]. Somit lässt sich der Radwiderstand F_{RD} entsprechend dem Rollwiderstand nach (2.6) berechnen [13, S. 15; 14, S. 58; 15, S. 139; 16, S. 101; 19, S. 60].

$$F_{RD} = c_{RW} \cdot F_N = c_{RW} \cdot m_{FZ} \cdot g \cdot \cos(\alpha) \quad (2.6)$$

Der Rollwiderstand je Rad ist über den Rollwiderstandskoeffizienten c_{RW} proportional zur Normalkraft F_N , die das Rad trägt, wie in Abb. 2.1 dargestellt. Dabei ist die Annahme, dass der nicht von der Normalkraft abhängige Lüfterwiderstand des Rads Teil des Luftwiderstands in (2.8) ist [14, S. 57/58; 20, S. 219]. Hingegen ist die Normalkraft F_N aller Räder über den Steigungswinkel α direkt von der am Rad wirkenden Gewichtskraft F_G abhängig. Entsprechend Abb. 2.2 liegt der Normalkraftangriffspunkt F_N längs vor der Radmitte. Diese Verschiebung geschieht bei der Drehung mit ω_{RD} und dem dabei verformten Gummi durch viskoelastische Dämpfung, welche die Druckverteilung in der Reifenaufstandsfläche in Fahrtrichtung nach vorne verschiebt [21, S. 476; 22, S. 164]. Dabei federt der Reifen beim Auftreffen auf die Fahrbahn im Latsch ein und die Flächenpressung nimmt mit dem Weiterdrehen zu. Nimmt die Einfederung hinter der Reifenmitte wieder ab federt der Reifen jedoch durch die Dämpfung nicht wieder mit gleicher Kraft aus, was die Druckverteilung nach vorne verschiebt. Die dabei durch Dämpfung dissipierte Wärmeenergie fließt in die Reifenteile. Sie fließt zu etwa 50 % in die Lauffläche, 20 % den Gürtel

sowie zu je 10 % in die Karkasse und die Seitenwände des Reifens. Der dadurch um den Hebelarm r_{RW} verschobene Druckmittelpunkt verursacht ein Gegenmoment zur Raddrehung, welches in Längsrichtung in der Rollwiderstandskraft F_{RD} resultiert. [18, S. 11–48]




Abb. 2.2: Ursache des Rollwiderstands [14, S. 56; 15, S. 142; 18, S. 30]

$$c_{RW}(\vartheta_u) = \frac{c_{RW}(25\text{ °C})}{1 + c_{RW,\vartheta} \cdot (\vartheta_u + 273,15\text{ K} - 25\text{ K})} \quad (2.7)$$

Da die viskoelastische Dämpfung mit höheren Temperaturen sinkt, fällt mit der Erwärmung des Reifengummis auch der Rollwiderstandskoeffizient c_{RW} . Dadurch ist der Rollwiderstandskoeffizient eines kalten Reifens im Vergleich zum warmen um bis zu 12 – 47 % höher [23, S. 60]. Bis nach Fahrtbeginn ein Temperaturgleichgewicht erreicht ist dauert laut ISO 28580 bei 80 km/h 30 Minuten [24]. Dagegen dauert das Erreichen des Temperaturgleichgewichts nur 10 Minuten bei 120 km/h aber bis zu einer Stunde bei 30 km/h [23, S. 61]. Übliche Rollwiderstandskoeffizientenwerte liegen bei Normbedingungen im Gleichgewichtszustand zwischen 0,006 und 0,013 [16, S. 102]. Das Temperaturgleichgewicht und damit c_{RW} ist jedoch von der Umgebungstemperatur ϑ_u , Geschwindigkeit und der Reifenkühlung insbesondere durch Nässe abhängig [25, S. 115]. Die Gleichung (2.7) modelliert die Umgebungstemperaturabhängigkeit mit dem Rollwiderstandstemperaturkorrekturfaktor $c_{RW,\vartheta}$ [24], wobei [26, S. 71] den Korrekturwert zwischen 0,006 und 0,010 1/°C angibt.

Damit entspricht eine 10 K Temperaturänderung einer Änderung in c_{RW} von ca. 6 bis 10 %, wie Messungen belegen [25, S. 154; 27, S. 8; 28, S. 95].

Bei Nässe ändert sich der Rollwiderstandskoeffizient c_{RW} nicht nur wegen der Gleichgewichtstemperaturänderung durch bessere Kühlung. Darüber hinaus verursacht gerade ein dickerer Wasserfilm einen relevanten Schwallwiderstand. Der Schwallwiderstand entsteht bei der Verdrängung des Wassers auf der Fahrbahn durch den Reifen. Zusätzlich gibt es eine reibungsbehaftete Durchströmung des Reifenprofils. Der zu verdrängende Wassermassenstrom sowie die Durchströmungsverluste sind stark geschwindigkeitsabhängig. Die beschriebenen wechselwirkenden Mechanismen führen laut Messungen bei z. B. 130 km/h mit einer leichten Fahrbahnbenetzung mit einem 0,2 mm Wasserfilm zu 55 % und bei starkem Regen mit einem 1 mm Wasserfilm schon zu 193 % Steigerung des Rollwiderstandskoeffizienten [25, S. 125; 28, S. 85]. Dies gilt für die volle Profilhöhe und ist von dieser abhängig [25, S. 125].

Daneben beeinflussen Art und Zustand des Fahrbahnbelages den Rollwiderstand [15, S. 140; 25, S. 145; 29, S. 112–113; 30, S. 87; 31, S. 205]. Der Rollwiderstandskoeffizient variiert zwischen einer Fahrt auf feinem Asphaltbeton und rauem Teer durch veränderte Eindringkräfte der Oberflächenrauigkeiten in die Reifenoberfläche um bis 122 % [15, S. 140]. Der Reifendruck beeinflusst zwar nur wenig den Eindringweg der Rauigkeiten, jedoch den Federweg des gesamten Reifenquerschnitts. Da die oben erläuterte Gummidämpfung über den gesamten Federweg wirkt, ändert sich der Rollwiderstandskoeffizient. Wie in [22, S. 168] modelliert, sinkt mit einer Reifendruckerhöhung um 1 bar über 2,1 bar Normdruck auch in Messungen der Rollwiderstandskoeffizient um 30 % [30, S. 83] bis 50 % [28, S. 69]. Neben Federweg und Temperatur beeinflusst auch die Fahrzeuggeschwindigkeit den Rollwiderstand. Die mit der Geschwindigkeit höhere Verformungsgeschwindigkeit erhöht den Einfluss der entgegenwirkenden Dämpfung in der Luft im Reifen und insbesondere im Gummi [21, S. 476; 27, S. 8; 32, S. 28]. Darüber hinaus bilden sich bei höheren Geschwindigkeiten im Reifen verlustbehaftete stehende Wellen aus [18, S. 13]. Verschiedene Messungen zeigen, dass der Geschwindigkeitseinfluss auf den Rollwiderstand ab etwa 100 km/h merklich ist [23, S. 12; 33, S. 25; 34, S. 597]. Einige Ansätze modellieren den Geschwindigkeitseinfluss [14, S. 59; 26,

S. 82]. Je nach Reifen steigert sich der Rollwiderstand um bis zu 77 % bei 150 km/h [23, S. 12; 28, S. 63].

Zusammenfassend ist festzustellen, dass es viele teils gegenläufige Einflüsse auf den Rollwiderstand und somit auf den Radwiderstand gibt. Eine genaue Modellierung dieser Zusammenhänge benötigt zum einen Kenntnis über viele Reifenparameter, v. a. aus Messungen, sowie über die entsprechenden Umgebungsbedingungen. Greiner [32] stellt ein detailliertes Prädiktionsmodell für Rollwiderstand vor. Dies kann aber gerade Fahrbahnrauigkeiten und Nässe noch nicht abbilden, welche im Feld oft einen sich überlagernden Einfluss haben. Dagegen kann eine Fahrwiderstandsschätzung, deren Möglichkeiten 2.2.2 erörtert, alle Feldeinflüsse im Mittel berücksichtigen [35].

Luftwiderstand

Die Luftwiderstandseigenschaften eines umströmten Körpers fasst der dimensionslose Luftwiderstandskoeffizient $c_{L,x}$ zusammen. Ist dieser für ein Fahrzeug mit der Stirnfläche A_x bekannt, so beschreibt (2.8) wie der Luftwiderstand F_L abhängig von der quadratischen Anströmungsgeschwindigkeit v_{rel} und der Luftdichte ρ_L ermittelt werden kann [13, S. 15; 14, S. 65; 15, S. 154; 16, S. 102; 18, S. 56; 19, S. 60]. Dabei ist $\rho_L \cdot v_{rel}^2 / 2$ der Staudruck, der sich vorne am Fahrzeugbug aufbaut. Somit entspricht der Luftwiderstandskoeffizient $c_{L,x}$ dem Anteil des Staudrucks, der bei der vorliegenden inkompressibler Umströmung hinter dem Fahrzeug nicht wieder aufgebaut werden kann [20, S. 77 & S. 102-103]. Integriert man den Druck an Fahrzeugbug und -heck über die Fahrzeugstirnfläche auf, resultiert die Luftwiderstandskraft. Erreichten Fahrzeuge um 1975 nur Luftwiderstandskoeffizienten von 0,45, so nähern sich heute Fahrzeuge mit günstigen Fahrzeuggrundformen eher 0,20 an [18, S. 62; 20, S. 365]. Die damit beschriebene Fahrwiderstandskraft eines Fahrzeugs teilt sich etwa in 80 % Druckwiderstand, 10 % Reibung auf der Außenhaut und 10 % Durchströmungswiderstand auf [20, S. 141–142]. Wegen der quadratischen Geschwindigkeitsabhängigkeit berücksichtigt diese Arbeit wie [20, S. 219] den Lüfterwiderstand der Räder als Bestandteil der Luftwiderstandskraft. Somit ist dieser Bestandteil im Luftwiderstandskoeffizienten berücksichtigt.

$$F_L = \frac{1}{2} c_{L,x} \cdot \rho_L \cdot A_x \cdot v_{rel}^2 \quad (2.8)$$

$$v_{rel} = v + v_{Wind} \quad (2.9)$$

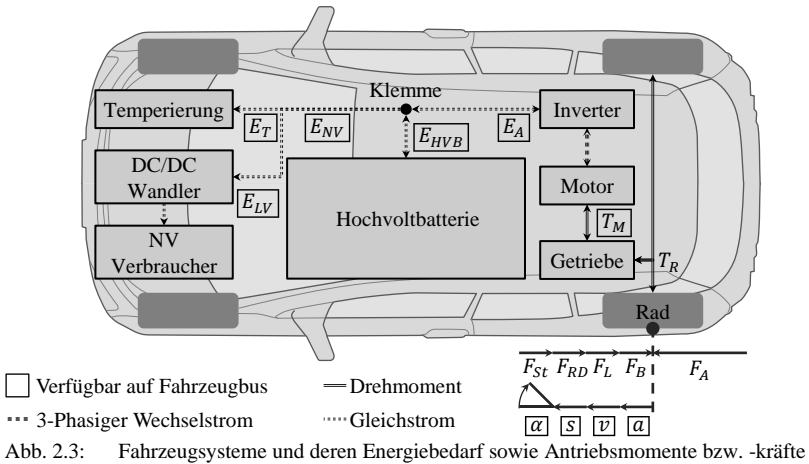
Wind beeinflusst über zwei Wege die Luftwiderstandskraft. Zum einen quadratisch über die veränderte Anströmgeschwindigkeit entsprechend (2.9), wobei die Windgeschwindigkeit v_{Wind} der Längsanteil des Windes ist. Der Wind weht über Land im höchsten Jahresmittel innerhalb Europa mit $6 \pm 3 \text{ m/s}$ in Irland [36, S. 2143]. Auch für die Vereinigten Staaten gibt [37, S. 7] Jahresmittelwindgeschwindigkeiten von bis zu $7,5 \text{ m/s}$ z. B. über den Great Plains an. Somit kommen Windgeschwindigkeiten bis etwa 10 m/s immer wieder vor. Zum anderen wirkt der Wind neben der Anströmgeschwindigkeit auch auf den Anströmwinkel ein. Der Luftwiderstandskoeffizient wiederum ist je nach Fahrzeugform mehr oder weniger abhängig vom Anströmwinkel [15, S. 155; 20, S. 142]. Bei Windgeschwindigkeiten bis 10 m/s treten im oberen Geschwindigkeitsbereich, in dem der Luftwiderstand dominiert, Anströmwickelveränderungen von bis zu 20° auf [18, S. 58; 20, S. 391]. Mit solchen Anströmwinkelveränderungen kann der Luftwiderstandskoeffizient um über 30 % steigen [20, S. 142]. Wie beschrieben verändert Wind über die Anströmgeschwindigkeits- und Anströmwinkelveränderung den Luftwiderstand.

$$\rho_L = \frac{p_u}{R_L \cdot (\vartheta_u + 273,15 \text{ K})} \quad (2.10)$$

Schließlich ändert sich der Luftwiderstand auch abhängig von der Luftdichte ρ_L . Die Luftdichte steigt entsprechend (2.10) mit steigendem Umgebungsdruck p_u , sinkt jedoch mit steigender Umgebungstemperatur ϑ_u und luftfeuchteabhängiger spezifischer Gaskonstante der Luft R_L [20, S. 142; 38]. So lässt sich zusammenfassen, dass viele Wettergrößen den Luftwiderstand verändern.

Wie die Fahrwiderstände den Radenergiebedarf bestimmen, beschreibt der Abschnitt oben. Dabei hat die Geschwindigkeit beim Luftwiderstand einen quadratischen Einfluss auf den Radenergiebedarf. Alle anderen Einflüsse, wie Beschleunigung, Steigung, Wettergrößen und Reifendruck, wirken entweder nur zeitweise und/oder wirken nicht quadratisch auf den Radenergiebedarf ein.

2.1.2 Fahrzeugsysteme



Nach der Erklärung der Abhängigkeiten des Radenergiebedarfs von den Fahrwiderständen, folgt die Erklärung der Funktionsweise und Effizienzeigenschaften der Komponenten eines elektrischen Antriebsstranges im batteriebetriebenen Elektrofahrzeug. Die Erklärung der Hochvolt-Komponenten erfolgt ausgehend vom Rad bis zum Energiespeicher, der HVB. Dabei geht der Abschnitt auch auf die Hochvolt- und Niedervolt-Nebenverbraucher ein. Damit gibt der folgende Abschnitt einen Überblick über den in Abb. 2.3 schematisch dargestellten Antriebsstrang und die Nebenverbraucher, insbesondere hinsichtlich des Energiebedarfs.

Getriebe

Zwischen Rad und Elektromotor übersetzt das Getriebe Drehzahl und Drehmoment. Dabei ist das Drehmoment am Rad gewöhnlich höher als an der Motorwelle. Entsprechend der – abzüglich Verluste – gleichbleibenden Leistungen auf beiden Seiten, ist das Verhältnis für die Drehzahl umgekehrt. Dabei wandelt ein Stirnrad- oder Vorgelegegetriebe bei Einzelradmotoren von der Motordrehzahl auf die Raddrehzahl [39, S. 4]. Wenn ein Motor mehrere Räder

antreibt, stellt ein Differenzialgetriebe aus der Radmitteldrehzahl des Stirnradgetriebeabtriebs die für die einzelnen Räder passende Drehzahlen bereit [40, S. 91]. Da ein Elektromotor ab Stillstand Drehmoment bereitstellen und die Richtung wechseln kann, haben Elektrofahrzeuge meist nur einen Gang und keine Kupplung [40, S. 92; 41, S. 109]. Mit einem Mehrgang-Getriebe kann der Elektromotor jedoch in effizienteren Betriebspunkten arbeiten, was für ein Zweigangetriebe in 4 – 11 % Systemwirkungsgradverbesserung resultieren kann [42, S. 1264; 43, S. 13]. Neben der Getriebeöltemperatur beeinflusst zudem der Betriebspunkt den Wirkungsgrad des Getriebes [13, S. 54; 41, S. 88]. Dabei beeinflussen hauptsächlich vier Mechanismen die Gesamtgetriebeeffizienz: momentenabhängige Verzahnungs- und Lagerverluste, sowie rein drehzahlabhängige Plansch- und Dichtungsverluste [39, S. 18; 41, S. 106]. Hierbei zählt diese Arbeit die Lagerverluste des Rades zur leichteren Erfassung zu denen des Getriebes. Insgesamt machen aber die Verzahnungsverluste den größten Teil der Getriebeverluste aus [41, S. 106]. Jeder Zahneingriff hat üblicherweise einen Wirkungsgrad von 99 % [39, S. 18]. Zusammen mit den anderen Verlusten übersetzt ein Getriebe im elektrischen Antriebsstrang Drehzahl und Moment üblicherweise mit etwa 98 % Wirkungsgrad in der zwischen Rad und Elektromotor übertragenen Leistung [44, S. 6].

Elektromotor

Der Elektromotor wandelt im elektrischen Antriebsstrang zwischen elektrischer und mechanischer Leistung und umgekehrt. Die meisten Elektroautos nutzen dazu Asynchron- oder permanenterregte Synchronmotoren [13, S. 86; 45, S. 29; 46, S. 699]. In den Wicklungen des feststehenden Stators eines Elektromotors fließt die elektrische Leistung und über die drehende Motorwelle gibt der darauf montierte Rotor die mechanische Leistung ab. Diese Leistung überträgt das Getriebe für die Überwindung der Fahrwiderstände an die Antriebsräder. Wie in 2.1.1 beschrieben, bewirkt hinreichend starkes Bremsen oder Bergabfahren eine negative Summe der Fahrwiderstände [40, S. 124–125]. Wenn es die Fahrstabilität zulässt, lässt sich dieser Überschuss rekuperieren [14, S. 364; 44, S. 4]. Beim Rekuperieren wandelt das Getriebe die an den Antriebsrädern verfügbare Kraft in ein an der Motorwelle bereitgestelltes Drehmoment bzw. mechanische Leistung. Der Elektromotor nimmt diese mechanische Leistung auf und wandelt diese in elektrische Leistung um. Somit

kann der Elektromotor nicht nur die benötigte Energie für den Fahrauftrag bereitstellen, sondern falls überschüssige kinetische oder potenzielle Energie verfügbar ist, diese auch in elektrische Energie umwandeln [13, S. 25].

Ein Elektromotor nutzt zur elektromechanischen Leistungswandlung die Lorentz- und/oder Reluktanzkraft [13, S. 83]. Die Lorentzkraft ist die Kraft die entsteht, wenn stromdurchflossene Leiter, hier die Motorwicklungen, sich in einem magnetischen Feld befinden [46, S. 692]. Wobei Magnete im Rotor das magnetische Feld in permanentenregten Synchronmotoren bereitstellen, während dies bei Asynchronmotoren in den Rotor induzierte Ströme tun. Zu diesem magnetischen Rotorfeld ist für die Lorentzkrafterzeugung das von der Statorwicklung erzeugte, rotierende Magnetfeld der Gegenspieler im magnetischen Kreis, welcher sich in Stator- und Rotorblechpaket bildet. Im Gegensatz zu der Lorentzkraft ist die Reluktanzkraft die Kraft, die versucht im magnetischen Kreis den geringsten magnetischen Widerstand einzustellen. Die Reluktanz, der Widerstand im magnetischen Kreis, im Luftspalt zwischen Rotor und Stator verändert sich v. a. durch eine versetzte Positionierung des Rotormagnetfelds zu dem Feld im Stator. Folglich lässt die Reluktanzkraft den Rotor dem drehenden Magnetfeld im Stator folgen [46, S. 693]. Gesamt ist der fließende elektrische Strom I proportional zur magnetischen Flussdichte B , welche wiederum proportional zum Motordrehmoment ist, welches Lorentz- und Reluktanzkraft verursachen [44, S. 36–42]. Letztendlich rotiert durch den elektrischen Wechselstrom in den Statorwicklungen ein Magnetfeld, das den Rotor mit einem Drehmoment rotieren lässt.

Gerade der elektrische Strom und das rotierende Magnetfeld verursachen Verluste im Motor. Der Ohm'sche Widerstand R bewirkt Verluste $P_{Vl,\Omega}$ entsprechend (2.11) in den Wicklungen, die der Strom I durchfließt [47, S. 458; 48, S. 669]. Das sich verändernde Magnetfeld hingegen verursacht über zwei Mechanismen Verluste, die sich nach dem Entstehungsort im Blechpaket auch Eisenverluste nennen [48, S. 669–670]. Der eine Teil sind die Hystereseverluste $P_{Vl,H}$ [44, S. 24; 47, S. 196; 49, S. 3398]. Die Hystereseverluste entstehen durch die unterproportional zur anregenden Feldstärke steigende und sinkende Flussdichte und deren Maximalwert B in der Masse m_{Fe} des Blechpaketes [47, S. 193-200]. Die Differenz zu einer proportionalen Änderung resultiert in Hys-

tereseverluste $P_{VI,H}$. Da sich dies mit der elektrischen Motorfrequenz f_M wiederholt, steigen die Verluste entsprechend (2.12) proportional mit der Frequenz an [44, S. 24; 47, S. 202]. Dabei beschreiben der empirische Koeffizient $c_{VI,H}$ (1,2 bis 4,8 abhängig vom Siliziumanteil im Eisenblech) und ebenfalls empirische Exponent k (1,5 bis 2,5) die Größe der Verluste. Wirbelstromverluste sind der zweite Anteil der Eisenverluste. Durch den wechselnden magnetischen Fluss in elektrisch leitenden Materialien werden Spannungen induziert, welche Wirbelströme verursachen [47, S. 197; 49, S. 3401]. Durch die Ströme entstehen Wirbelstromverluste $P_{VI,W}$ abhängig vom materialabhängigen spezifischen elektrischen Widerstand ϱ , entsprechend Gleichung (2.13) [44, S. 24; 47, S. 199; 50, S. 623]. Die Wirbelstromverluste sind also proportional zur quadratischen elektrischen Motorfrequenz f_M und zu der quadratischen Materialdicke d , senkrecht zum magnetischen Fluss gemessen, sowie zu dem Volumen V des ferromagnetischen Materials. Beide Eisenverlustanteile, Hysteres- und Wirbelstromverluste, sind zumindest näherungsweise proportional zur quadratischen Flussdichte B , die, wie oben beschrieben, selbst proportional zum elektrischen Strom und zum Motormoment ist. Folglich sind beide Eisenverlustanteile und die Ohm'schen Verluste näherungsweise proportional zum quadratischen Motormoment.

$$P_{VI,\Omega} = I^2 \cdot R \quad (2.11)$$

$$P_{VI,H} = c_{VI,H} \cdot m_{Fe} \cdot f_M \cdot B^k \quad (2.12)$$

$$P_{VI,W} = \frac{V \cdot \pi^2 \cdot f_M^2 \cdot d^2 \cdot B^2}{6 \cdot \varrho} \quad (2.13)$$

Neben den Verlusten im Motor mit elektromagnetischen Ursachen, gibt es auch mechanische Reibungsverluste [48, S. 669]. Zum Einen verursacht Reibung in den Lagern der Motorwelle Lagerungsverluste, deren Größe abhängig von der Drehzahl ist [47, S. 460]. Zum Anderen entstehen durch die Luftreibung am Rotor insbesondere am Luftspalt Ventilationsverluste, die proportional zur quadratischen Drehzahl ansteigen [47, S. 461; 51]. Insgesamt sind die Reibungsverluste jedoch von untergeordneter Bedeutung [47, S. 458]. Weiterhin lässt sich zusammenfassen, dass die Gesamteffizienz des Elektromotors

abhängig vom Betriebspunkt ist, aber meist über 85 % oder sogar 90 % Wirkungsgrad liegt [16, S. 74–75].

Inverter

Ein Inverter, auch Leistungselektronik genannt, stellt aus der Gleichspannung der Batterie den für den Elektromotor je nach Betriebspunkt nötigen Wechselstrom bereit und regelt diesen. Dazu stellen im Inverter Halbleiterschalter die Ströme so, dass sich näherungsweise ein sinusförmiger Wechselstrom ergibt [13, S. 99]. Bei den in Elektrofahrzeugen verwendeten Dual Mode Invertern geschieht dies jedoch auch umgekehrt: Der Inverter richtet rekurperierten Wechselstrom gleich [40, S. 93; 45, S. 39; 52, S. 634]. Wie in allen stromführenden Leitern oder Schaltungen, entstehen dabei durch den Ohm'schen Widerstand Verluste, wie es (2.11) beschreibt. Jedoch sind diese Verluste durch die verwendeten Halbleiterschalter nicht nur quadratisch sondern auch direkt zum Strom proportional [53, S. 1824; 54, S. 1753]. Schaltverluste rufen diesen zusätzlichen direkt proportionalen Anteil hervor [16, S. 94; 55, S. 611]. Die Schaltverluste bestehen aus Ein- und Ausschaltverlusten [44, S. 59]. Dabei macht eine Schaltspannungsversorgung den zunächst nichtleitenden Halbleiter leitend. Gleichzeitig ruft der sich abbauende Widerstand mit dem bereits fließendem Strom einen Verlust hervor und anders herum [44, S. 61–62]. Abhängig von der Schaltfrequenz f_s geht der Schaltenergieverlust $P_{VL,S}$ verloren, was entsprechend (2.14) insgesamt zu dem Schaltverlust $P_{VL,S}$ führt [16, S. 94]. Wobei der Schaltenergieverlust $E_{VL,S}$ bei Referenzstrom I_0 und -spannung U_0 angegeben ist und auf den Strom I und die Zwischenkreisspannung U im Betriebspunkt bezogen werden muss. Dabei beeinflusst die Bauteiltemperatur die Schaltverluste und den Leitungswiderstand [56, S. 1–3], jedoch ist die Temperatur durch die geregelte Kühlung nahezu konstant anzunehmen. In der Gleichung (2.14) ändert sich mit konstant angenommener Zwischenkreisspannung aus der Batterie nur der Betriebspunkt des Stroms, welcher proportional zum Motormoment ist [44, S. 36–42]. Dabei sind die nur von der konstruktiv festgelegten Schaltfrequenz abhängigen Schaltverluste bis zu dreimal so groß wie die Leitungsverluste im Inverter [54, S. 1755]. Insgesamt liegt der Wirkungsgrad der Inverter bei bis zu über 95 % [16, S. 94; 54, S. 1754].

$$P_{VL,S} = \frac{f_S \cdot E_{VL,S} \cdot I \cdot U}{\pi \cdot I_0 \cdot U_0} \quad (2.14)$$

Hochvoltbatterie

Die HVB dient als chemischer Speicher elektrischer Energie im Elektrofahrzeug [40, S. 104]. Dabei stammt die gespeicherte Energie aus dem Stromnetz aber auch aus Rekuperation während der Fahrt [40, S. 59]. Die HVB stellt dazu Gleichstrom aus mehreren, üblicherweise Lithiumionenzellen bereit [45, S. 24; 57, S. 71]. Solche Zellen bestehen aus zwei Elektroden, die geladene Teilchen durch einen Separator und über den parallelen Last- bzw. Ladestromkreis austauschen [13, S. 106]. In den Zellen lagern sich beim Laden positiv geladene Lithiumionen in der Anodenstruktur ein, wobei der Ladestrom die für die Bindung nötigen Elektronen bereitstellt. Die Lithiumionen kommen aus einer lithiumoxidhaltigen Schicht an der Kathode und wandern durch den Separator in die Graphitstruktur der Anode [40, S. 109–110]. Beim Entladen werden die Lithiumionen aus der Graphitatomstruktur wieder ausgelagert und wandern zurück durch den Separator. Parallel fließen über den Laststromkreis Elektronen zurück zur Kathode, welche parallel den nutzbaren, elektrischen Strom bilden [40, S. 109–110; 58, S. 8]. Dieser Ladungsaustausch unterliegt Verlusten. Das Laden und Entladen geschieht mit einer Effizienz zwischen 82 und 94 % je nach spezifischer Zellchemie und Betriebspunkt [59, S. 2]. Um die bereitstellbare Energie zu schätzen, ermitteln verschiedene Algorithmen neben der Kapazität im Batterieersatzmodell auch den Innenwiderstand, um Lade- und Entladeverluste zu berücksichtigen [60, S. 975; 61]. Wobei je nach Modell der kleinste Fehler bei 0,7 bis 2,4 %-SOC-Punkten (State of Charge; eng.: Ladezustand) liegt [62, S. 416]. Jedoch steigt der relative Schätzfehler mit sinkendem SOC. So können es bei einem realen SOC von 50 % bis zu 4,8 % relativer Fehler sein. Dabei beeinflusst der SOC neben Zelltemperatur, Leistungsverlauf und Alterungszustand der HVB den zu schätzenden Innenwiderstand und somit auch die Verluste in der HVB [60, S. 972; 63, S. 99; 64, S. 101; 65, S. 406]. Die optimale Zelltemperatur bezüglich Innenwiderstand und Lebensdauer liegt bei 20 – 40 °C. Unter diesem Temperaturniveau steigt der Innenwiderstand überproportional. Über diesem Temperaturniveau verringert sich die Batterielebensdauer beträchtlich. Daher benötigen Lithiumionenbatterien eine Temperierung, wobei der SOC-Schätzer abhängig davon arbeitet [58,

S. 165-167]. Zusammengefasst speichert die HVB chemisch Energie, wobei ein SOC-Schätzer die noch verfügbare Energie abschätzt.

Nebenverbraucher

Neben dem Antriebsstrang benötigen weitere Komponenten, die Nebenverbraucher, Energie aus der HVB. Dazu zählen sicherheitsrelevante Komponenten, wie Licht, Scheibenheizung, Brems- und Lenkunterstützung, aber auch verschiedene Komfortverbraucher, wie Infotainment, Lenkrad- und Sitzheizung sowie Innenraumtemperierung [13, S. 137; 16, S. 70]. Dabei versorgt ein Gleichstromspannungswandler alle Nebenverbraucher außer der Innenraumtemperierung mit einer niedrigeren Spannung als der Spannung von der HVB [27, S. 3; 66, S. 27]. Denn gerade die Innenraumtemperierung benötigt im Mittel, aber insbesondere auch in der Spitze, am meisten Leistung nach dem Antrieb [67, S. 25; 67, S. 184]. Der sich ergebende Energiebedarf ist abhängig von der Umgebungstemperatur für Kühlen oder Heizen des Innenraumes notwendig, was einen großen Einfluss auf den Gesamtenergiebedarf hat [27, S. 6]. Dabei übernimmt das Heizen in der Regel ein elektrisches PTC-Heizelement (Positive Temperature Coefficient) oder eine Wärmepumpe, da quasi keine Abwärme verfügbar ist, anders als beim Verbrennungsmotor [68, S. 397–399; 69, S. 261]. Dagegen nutzt die Innenraumkühlung einen Kältekreislauf mit einem elektrischen Klimakompressor [27, S. 3; 69, S. 202]. Dabei ist der Energiebedarf von beiden abhängig von der aktuellen Innenraum- und der Umgebungstemperatur sowie der Luftfeuchte, Anströmgeschwindigkeit und der Sonneneinstrahlung im Zusammenhang mit den Klimageräteeinstellungen [69; 70, S. 23]. Neben dem Innenraum ist auch die HVB zum Bauteilschutz zu temperieren [69, S. 2578]. Die Temperierung des Innenraumes benötigt gerade dann viel Leistung, wenn dessen Temperatur in instationären Aufheiz- oder Abkühlphasen noch nicht der Solltemperatur entspricht. Ist die Solltemperatur eingestellt, benötigt die quasistationäre Erhaltung weniger elektrische Leistung als zuvor. Insgesamt kann der Hauptnebenverbraucher Temperierung beim Heizen mit PTC-Heizelementen bis zu 5 kW und beim Kühlen im Maximum bis zu 7 kW benötigen [27, S. 8; 69, S. 83-84, 140].

2.1.3 Betrachtetes System

Insgesamt setzt sich der Fahrzeugenergiebedarf E_{HVB} bzw. das zeitliche Integral der Leistung P_{HVB} , erfasst an der Klemme der HVB, aus Nebenverbraucher- E_{NV} und Antriebsenergiebedarf E_A zusammen, entsprechend (2.15). Dabei ist nach (2.16) der Antriebsanteil das Integral der Fahrwiderstandskräfte F_{FW} über den gefahrenen Weg s , unter vollständiger Berücksichtigung der oben erläuterten Verluste bzw. Effizienzen η_A der Komponenten. Die Effizienzen fließen dabei nach (2.17) abhängig von der Geschwindigkeit, der Richtung, nämlich Vortrieb V oder Rekuperation R , und Größe der Fahrwiderstandskräfte ein. Neben dem damit ermittelten Antriebsenergiebedarf beziehen, wie oben beschrieben, auch die Nebenverbraucher Energie aus der HVB. Die verbrauchte Energie besteht wiederum aus Energiebedarf auf HVB-Spannung für die Fahrzeugtemperierung E_T und für das Niedervoltbordnetz E_{LV} über den DC/DC-Wandler auf abgesenkter 12 V Spannung. Deren Leistungsbedarfe P_T und P_{LV} sind aber im Gegensatz zum Antriebsbedarf rein von der Betriebszeit t und nicht vom Weg abhängig. Da sich der Weg auch über die Zeit beschreiben lässt, nutzt (2.15) für den Gesamtleistungsbedarf des Elektrofahrzeuges das zeitliche Integral, um den Energiebedarf zu beschreiben.

$$E_{HVB} = \int P_{HVB} dt = E_A + E_{NV} \quad (2.15)$$

$$E_A = \int \eta_A(F_{FW}, v) \cdot F_{FW} ds \quad (2.16)$$

$$\eta_A(F_{FW}) = \begin{cases} \eta_{A,R} & \text{wenn } F_{FW}(s) < 0 \\ \frac{1}{\eta_{A,V}} & \text{wenn } F_{FW}(s) \geq 0 \end{cases} \quad (2.17)$$

$$E_{NV} = E_T + E_{LV} = \int P_T + P_{LV} dt \quad (2.18)$$

Nach der Beschreibung der Zusammenhänge des Energiebedarfs im Elektrofahrzeug und der beteiligten Fahrzeugkomponenten, erläutert dieser Abschnitt die Systemgrenze der Routenenergiebedarfsprognose. Die in 1.1 beschriebenen Anwendungen, energetisch planende Algorithmen, benötigen eine Routenenergiebedarfsprognose. Jedoch benötigen die Anwendungen meist auch

die Energie, die die HVB den Verbrauchern an der Klemme bereitstellen kann. Diese verfügbare Energie stellt die SOC-Schätzung der HVB bereit, wie in 2.1.2 unter Hochvoltbatterie erläutert. Für einen zuverlässigen Betrieb der HVB veranlasst das Batteriemanagement eine Batteritemperierung, wenn notwendig. Diese Temperierung ist jedoch eine Funktion der HVB, daher muss das Batteriemanagement den Energiebedarf dafür an die Routenenergiebedarfsprognose übermitteln bzw. in der SOC-Schätzung berücksichtigen. Wie in 2.1.2 genauer beschrieben, ist die Funktionsweise der SOC-Schätzung bereits Ergebnis verschiedener Forschungsarbeiten [60–62]. Daher berechnet die Routenenergiebedarfsprognose nur die Summe des Antriebs- und Nebenverbraucherenergiebedarfs an der Batterieanschlussklemme entlang einer Route. Wie in Abb. 2.3 dargestellt, dient die Batterieanschlussklemme als Systemgrenze zwischen der Routenenergiebedarfsprognose und der Bestimmung der verfügbaren Energie. Wobei entsprechend dem Ziel in 1.2 nur die Routenenergiebedarfsprognose an der Batterieklemme Forschungsgegenstand in dieser Arbeit ist.

2.2 Prognosemodelle des Routenenergiebedarfs

Dieses Kapitel gibt einen Überblick zu bereits bekannten Modellen zur Prognose des Energiebedarfs und deren Anwendungen. In der häufigen Anwendung der Reichweitenprognose gibt es Modelle unabhängig von Routen [71; 72], jedoch liegt hier der Fokus auf solchen für Routen, entsprechend der Zielsetzung in 1.2. Zu diesen Modellen gibt 2.2.1 zunächst einen Überblick über die Hauptkategorien und die bekannten Modelle sowie deren Vor- und Nachteile. Für die in 2.2.1 favorisierte Kategorie beschreiben 2.2.2 bis 2.2.4 genauer, was für die dafür notwendigen Teilmodelle bekannt ist.

2.2.1 Modellüberblick

Es gibt verschiedene veröffentlichte Ansätze, den Energiebedarf vorherzusagen. Dazu zeigt Tab. 2.1 einen Überblick, gegliedert in Modelltypen und die

Zur Reichweitenprognose nutzt [77] Verbrauchsmesswerte auf vorausliegenden Streckenabschnitten von anderen ähnlichen Fahrzeugen. Dabei setzt das Modell den Verbrauch mit Fahrstil, Fahrzeuggewicht und Wunsch-Innenraumtemperatur aus den Flottenmessungen in Verbindung. Ein Server übermittelt die gemessenen Daten zwischen den Fahrzeugen, wobei [77] hier auch ergänzende Wetter- und Verkehrsdatenberücksichtigung im Modell vorschlägt, aber nicht konkreter erläutert. Auch sich ändernde Fahrzeugeigenschaften sowie ein Informationsübertrag von andersartigen Fahrzeugen ist nicht vorgesehen.

Kennfeldbasierte Modelle

Um in der Logistik kosten- und energieeffiziente Routen zu finden, nutzt [78] eine statistisch ermittelte Linearisierung des Energiebedarfs über der Geschwindigkeit. Dabei wählt ein Mixed Integer Linear Programming Algorithmus zwischen Geschwindigkeitsgrenzen die Geschwindigkeit. Dieses lineare Modell ist jedoch nur in der Lage, die komplexen Zusammenhänge grob zu erfassen und es vereinfacht Umgebungs- und Dynamikeinflüsse.

Für eine Energiebedarfsprognose als Grundlage für Ladeinfrastrukturplanung und intelligente Dienstleistungen nutzt [79] ein statistisch aus Flottendaten ermitteltes Kennfeld. Dieses Kennfeld ist ein Polynom zweiter Ordnung, ergänzt um einen inversen Geschwindigkeitsfaktor. Dabei stützt sich dieses einfache Modell nur auf Geschwindigkeitsdaten bis 50 km/h und ist somit nicht ohne Weiteres auf alle Straßentypen übertragbar.

Um eine energieeffiziente Route zu berechnen, verwendet [80] ein polynom-basiertes Kennfeld. Das Modell stützt sich dabei neben der Steigung nur auf den Einfluss der mittleren Geschwindigkeit je Straßenabschnitt von einer Flotte. Dieses einfache Modell vernachlässigt zwar energetische Einflüsse wie die Umgebungstemperatur und sich ändernde Fahrzeugeigenschaften, aber berücksichtigt über die Flottendaten verkehrsabhängige Geschwindigkeiten. Da es sich um einen einfachen Ansatz handelt, soll dieser Ansatz als Repräsentant der kennfeldbasierten Modelle in dieser Arbeit als Vergleichsmodell dienen.

Machine-Learning-Modelle

Zur Reichweitenprognose und zum Finden von effizienten Routen nutzt [81–83] einen zweistufigen Machine-Learning-Ansatz basierend auf Karteninformationen. So ermittelt ein neuronales Netz abhängig von Ampelpositionen, Straßengeometrie, und -typ sowie Tageszeit sieben Fahrprofilparameter. Mit dieser Fahrprofilinformation prädiziert eine lineare Regression den Energiebedarf. Entsprechend der statischen Karteninformation und einer fehlenden Modellierung des Fahrereinflusses ist dieses Modell nur eingeschränkt in der Lage alle energetischen Einflüsse abzubilden.

Ein Machine-Learning-Modell prognostiziert den Energiebedarf in [84–86] mit einem General Regression Neuronal Network. Dabei nutzt es aus den Kartendaten nur die Straßenklasse und die Steigung als Information über die vorausliegende Strecke. Über die Tageszeit kann das Modell zwar tendenziellen typischen Verkehr berücksichtigen, aber wegen einer fehlenden Vernetzung mit anderen Fahrzeugen keine streckenspezifische Prognose sicherstellen.

Als Basis für eine Reichweitenberechnung nutzt [87] ein Clustering-Verfahren zur Energiebedarfsprognose. Dieser Machine-Learning-Ansatz nutzt Fahrprofilinformation als Eingangsinformation, die aus Kartendaten der vorausliegenden Strecke und historischen Statistiken aus dem eigenen Fahrzeug generiert wird. Dabei nutzt das Verfahren zwar Echtzeitverkehrsinformation und kann das Fahrerverhalten statistisch mit einbeziehen, jedoch fließen andere energetische Einflüsse, etwa aus der Umgebung oder von fahrtspezifischen Fahrzeugigenschaften, nicht ein.

Energetisch nachsimulierte Fahrprofildaten einer Fahrzeugflotte nutzt die Support Vector Regression in [66; 88–91] in dem für elektrische Fahrzeuge favorisierten dezentralen Ansatz zur Energiebedarfsberechnung zur Reichweitenprognose. Dabei lernt dieser Machine-Learning-Ansatz für jeden Fahrer ein Modell an, das entsprechend der Flotteninformationen sowie Wetter- und Verkehrsdaten je Streckenabschnitt verschieden gewichtet. Dabei kann das Modell jedoch nicht den energetischen Einfluss von Wind und sich ändernden Fahrwiderständen berücksichtigen. Zudem benötigt das Modell eine große Anzahl

an Fahrprofilkennzahlen, entsprechend [105]. Diese lassen jedoch nicht alle direkten physikalischen Rückschlüsse auf deren energetischen Einfluss zu.

Zur Prognose des Antriebsenergiebedarfes nutzt das Machine Learning in [1] eine lineare Regression basierend auf Fahrprofilinformationen einer prototypischen Flotte. Neben dem im konstanten Achsabschnitt der linearen Regression approximierten Rollwiderstands- und Steigungseinfluss, besteht die Fahrprofilinformation nur aus zwei Variablen, einer weg- und gewichtsnormierten positiven (*PKE*) und negativen kinetischen Energieverbrauchsrate (*NKE*) entsprechend (2.19) bzw. (2.20). Darin aggregieren die beiden Parameter vorzeichenabhängig die quadratische Änderung in der Geschwindigkeit v zwischen jeder i -ten von k verfügbaren Messungen je Streckenabschnitt. Dabei normiert die Aggregation die Parameter über dem Weg s . Diese Parameter spiegeln zwar nicht den tatsächlichen Energiefluss wider, wie 4.3 zeigt, und das Modell ist nicht fahrerspezifisch, jedoch ist es ein simpler und vielversprechender Ansatz, der Flotteninformationen zugänglich macht. Da die Validierung nur auf drei Strecken mit Geschwindigkeitsbegrenzungen unter 110 km/h und einem einzigen Fahrzeug erfolgte, soll diese mit umfangreicheren Daten in dieser Arbeit wiederholt erfolgen, welche 4.4.4 beschreibt.

$$PKE = \frac{\sum_{i=1}^k \max(v_{i+1}^2 - v_i^2, 0)}{\sum_{i=1}^k s_{i+1} - s_i} \quad (2.19)$$

$$NKE = \frac{\sum_{i=1}^k \min(v_{i+1}^2 - v_i^2, 0)}{\sum_{i=1}^k s_{i+1} - s_i} \quad (2.20)$$

Das auf Machine Learning basierende zweistufige Energiebedarfsmodell [92] nutzt fein aufgelöste Daten zur Prognose des Energiebedarfs. Dabei berücksichtigt es Umgebungseinflüsse, Nebenverbraucher und Fahrprofileinflüsse. Diese lernt und prädiziert ein Convolutional Neuronal Network, dessen Ergebnisse nachfolgend ein Bagged Decision Tree korrigiert. Das vielversprechende Modell lässt jedoch offen, wie die hochaufgelösten Eingangsdaten prognostiziert werden sollen.

Zur Reichweitenprognose nutzt das maschinell lernende Energiebedarfsprognosemodell [93] Daten einer elektrischen Pekingener Taxiflotte. Dazu generiert eine Markov-Kette die für die Prognose notwendigen Fahrprofilparameter aus den historischen Daten. Darauf basierend prädiziert die Decision-Tree-Variante XGBoost von [106] den Energiebedarf. Dabei berücksichtigt das Modell zwar energetische Verkehrs-, Fahrer- und Umgebungseinflüsse, jedoch nicht sich möglicherweise ändernde Fahrzeugparameter.

Für wahrscheinlichkeitsbasierte vorausschauende Regelungssysteme von Fahrzeugsystemen wie dem Thermomanagement einer elektrischen Maschine verwendet [104] eine stochastische Vorhersage von Geschwindigkeit und Radleistung. Das Modell berechnet aus Streckendaten zu Straßengeometrie und -klasse sowie Geschwindigkeitsbegrenzung Fahrprofilgrößen und die Radleistung. Dabei nutzt das Modell stochastische Prozessmodellierung mittels Zeitreihenmodellierung über autoregressive Prozesse und Markov-Ketten zur Prognose einer erwarteten Gaußverteilung der Vorhersage. Notwendige Parameter ermittelt das Modell mittels rekursiver Schätzer. Dabei ist das Fahrerverhalten in Form von Längs- und Querdynamikgrenzen sowie dem Verhalten relativ zur Geschwindigkeitsbegrenzung abgebildet. Allerdings bleibt der Einfluss von Verkehr und Wetter im Modell unberücksichtigt.

Physikalische Modelle

Das physikalische Energiebedarfsprognosemodell [94–96] verwendet Karteninformationen. Dabei passt eine Fahrwiderstandsschätzung aus Fahrzeugdaten die Fahrzeugparameter der Fahrwiderstandsgleichung an und ein gleitender Mittelwert lässt das Fahrverhalten in die Prognose einfließen. Zwar berücksichtigt die Prognose den Einfluss des Windes, jedoch ist z. B. der Temperierungsenergiebedarf nicht durch eine Wetterprognose gestützt. Darüber hinaus lassen die Kartendaten nur die Berücksichtigung von Übergangs- und Kurvenbeschleunigungen zu. Der Einfluss etwa von Verkehr bleibt unberücksichtigt.

Mit dem Ziel energieeffiziente, elektrisch gefahrene Bus-Routen zu bestimmen, nutzt [97] ein physikalisches Modell. Dieses berechnet den Energiebedarf basierend auf Fahrprofilen generiert aus Kartendaten. Dabei ist kein Fahrer-

oder Verkehrseinfluss berücksichtigt und trotz wechselnder Passagierzahlen wird nur eine gemittelte Masse angenommen.

Das physikalische Energieprognosemodell [98] basiert auf hochaufgelösten Fahrprofilen. Deren Geschwindigkeitsverlauf ermittelt eine auf historischen Fahrprofilstatistiken basierende Fahrprofilprädiktion aus Karten- und Echtzeitverkehrsdaten. Dabei berücksichtigt es Fahrer- und Verkehrseinflüsse. Trotz der temperaturabhängigen Nebenverbrauchsprädiktion vernachlässigt das Modell andere Wiedereinflüsse wie Wind. Auch Fahrwiderstandsunterschiede berücksichtigt dieses rechenaufwendige, zeitlich hochaufgelöste Modell nicht.

Das physikalische Energiebedarfsprognosemodell [99] nutzt statistisch ausgewertete Flottengeschwindigkeitsinformation zusammen mit einem verkehrabhängigen Fahrermodell. Dazu lernt das Fahrermodell das Geschwindigkeitsverhalten, abhängig vom aus Fahrzeugdaten ermittelten aktuellen Verkehrszustand. Dabei berücksichtigt das Modell jedoch nur Beschleunigungen zwischen Straßenabschnitten unterschiedlicher Geschwindigkeiten und vernachlässigt den Dynamikeinfluss. Aus den Fahrzeugdaten parametrisiert eine Fahrwiderstandsschätzung auch das physikalische Modell, jedoch berücksichtigt dieses keine Umgebungseinflüsse, wie Wind.

Für den Zweck einer abgestimmten Planung der Routen aller Fahrzeuge in einem Straßennetzwerk zur übergreifenden Reduktion von Verkehrsdichte und Energiebedarf in Elektrofahrzeugen, berechnet ein physikalisches Modell in [100] den Energiebedarf je Streckenabschnitt. Dafür ist die Voraussetzung, dass ein relevanter Anteil der Verkehrsteilnehmer ihre geplante Route einer zentralen Verkehrsplanungsinstanz senden. Aus dieser Flotteninformation generiert die Planungseinheit verkehrsdichteabhängige erwartete Geschwindigkeiten für das energetische Modell. Dieses bildet zwar alle physikalischen Einflüsse bei Konstantfahrt ab, nutzt aber nur fixierte Übergangsbeschleunigungen und geht nicht auf Rekuperation ein. Zudem ist das Modell nicht in der Lage, direkt von der Flotte Dynamikinformationen zu verarbeiten, was Beschleunigungen z. B. im zähflüssigen Verkehr vernachlässigt.

Zum Ermitteln von energieeffizienten Routen schlägt [101] ein physikalisches Modell vor, das sich auf direkt zwischen Fahrzeugen ausgetauschten Fahrpro-

filinformationen stützt. Dabei ist das Modell auf die in der Umgebung befindlichen Fahrzeuge in der Echtzeitvorausschau begrenzt. Zudem vernachlässigt das Modell den Einfluss des Fahrers, der Nebenverbraucher sowie veränderlicher Fahrwiderstandsgrößen.

Zur Prognose von Energiebedarf und Treibhausgasausstoß von hochautomatisierten elektrischen Taxis nutzt [102] ein physikalisches Modell, das sich auf Daten der New Yorker Taxiflotte stützt. Das Modell bildet durch die hochaufgelösten Daten den Fahrprofileinfluss über verschiedene Fahrer und Verkehrssituationen sowie variierende Umgebungsbedingungen sowie Fahrzeugparametervariationen ab. Jedoch ist dieses Modell auf kontinuierliche Fahrprofiledaten angewiesen, die in einer Prognose für vorausliegende Routen nicht vorliegen.

Das physikalische Modell von [103] schlägt vor, Leistungsparameter je Streckenabschnitt zwischen Fahrzeugen auszutauschen, zeigt aber nur die prinzipielle Machbarkeit. Dieses energetische Prognosemodell dient in [103] dazu, energieeffiziente Routen für verschiedenste Fahrzeuge zu generieren. Dabei vernachlässigt dieser Ansatz jedoch den Einfluss des Fahrers. Daneben sieht der Ansatz zwar einen Echtzeitaustausch der Leistungsparameter zwischen den Fahrzeugen vor, was entsprechend den Verkehrseinfluss berücksichtigt. Dies ist jedoch für lange Routen über Städte hinweg nicht verwendbar, da sich die Verkehrsverhältnisse bis zur Ankunft erheblich ändern könnten.

Diskussion der Modelltypen

Die bisher einzeln vorgestellten Modelle werden nun je Modelltyp bezüglich ihrer Vor- und Nachteile diskutiert. So nutzen direkte Modelle nur aufgezeichnete Energiewerte verschieden räumlich gegliedert, ohne zusätzliche Informationen zur Prognose. Jedoch ist der Energiebedarf, wie 2.1 erkennen lässt, von weit mehr als dem Ort abhängig. So hat daneben das Fahrprofil mit Beschleunigungen und Geschwindigkeiten wesentlichen energetischen Einfluss. Dazu bilden Kennfeldmodelle zumindest die Geschwindigkeitsabhängigkeit ab und könnten somit z. B. von Verkehrs- und Fahrereinflüssen einen Teil erfassen. Gerade den Einfluss veränderlicher Fahrzeugeigenschaften sowie Umgebungseinflüsse, wie z. B. das Wetter können diese Kennfelder aber auch nicht

widerspiegeln. Um die wichtigen Einflüsse von Strecke, Umgebung, Verkehr, Fahrer und Fahrzeug zu berücksichtigen, kann Machine Learning mit den richtigen Eingangsgrößen diese im Modell implizit anlernen. Jedoch nehmen viele dieser Modelle ein immer unverändertes Fahrzeug an, was eine allmähliche Modellanpassung wie in [66, S. 53–58] oder ein neues Anlernen mit vielen Trainingsdaten notwendig macht. Erfolgt dieses umfassende Training nicht, besteht die Gefahr, dass das maschinell angelernte Modell außerhalb seines Trainingsdatenraumes mit großen Fehlern prognostiziert. Dagegen gibt es bei physikalischen Modellen keine Grenzen des Definitionsraumes und die Zusammenhänge sind transparent und nachvollziehbar modelliert. Darüber hinaus können physikalische Modelle veränderte Fahrzeugparameter umgehend explizit berücksichtigen, wie z. B. in [99]. Folglich sind physikalische Modelle wegen des uneingeschränkten Definitionsbereiches und der expliziten und nachvollziehbaren Anpassbarkeit zu bevorzugen.

Informationsquelle

Dabei haben alle genannten Energiebedarfsprognosemodellen eins gemein. Sie benötigen entweder Information zum Fahrprofil oder direkt Energiebedarfswerte. Dafür können Modelle die Information aus einer digitalen Karte [78; 81–87; 94–98; 104] aber auch aus Fahrzeugdaten vom Ego-Fahrzeug [73–76; 84–87; 94–96; 99; 104] oder von einer Fahrzeugflotte [1; 66; 77; 79; 80; 88–93; 99–103] beziehen. Dabei ist es nur möglich den Energiebedarf direkt aus Fahrzeugdaten zu beziehen. Denn digitale Karten im Navigationssystem enthalten nicht fahrzeugspezifische, sondern umgebungsspezifische Informationen je Streckenabschnitt, wie Geschwindigkeitslimits, eine allgemeine mittlere Geschwindigkeit, Steigung, Abzweigungen und Kurven sowie Standorte von Ampeln und Schildern. Diese vorliegenden Merkmale in der Karte lassen jedoch mehr oder weniger indirekte energetische Schlüsse zu. Nur mit Fahrzeugdaten des eigenen Fahrzeuges kann ein Modell fahrerspezifische oder sich ändernde energetische Fahrzeugeinflüsse berücksichtigen. Da die eigenen Fahrzeugdaten jedoch keine Informationen über die zu prognostizierende Route enthalten, verwenden Modelle die eigenen Fahrzeugdaten ergänzend, wenn nicht direkt Energien gespeichert sind. Die direkt verwendeten Energien aus dem eigenen Fahrzeug sind zwar spezifisch, aber nur Energien aus anderen Fahrzeugen, also aus Flottendaten, lassen eine Prognose auch für unbefahrene

Streckenabschnitte zu. Flottendaten können auch andere als die direkten Modelle verwenden. So können, anders als Karteninformationen, Flottendaten streckenspezifische Fahrprofilinformationen explizit erfassen, welche einen wesentlichen energetischen Einfluss haben. Zudem kann ein Fahrermodell über Flottenstatistiken lokale Fahrprofileinschränkungen aus dem Flottenverhalten erfassen. Dementsprechend sollte ein Energiebedarfsprognosemodell als Informationsquelle Flottendaten um eigene Fahrzeugdaten ergänzt bevorzugen. In Kombination mit einem physikalischen Modell ergibt sich, wie oben erläutert, die zu favorisierende Modellausprägung bezüglich Modelltyp und Informationsquelle.

Diese Kombination zeigt bisher nur [99]. Jedoch fehlen einige der zu modellierenden energetischen Einflüsse entsprechend 2.1. Dort zeigt sich, dass folgende drei Einflussgruppen einfließen müssten. Als erstes müssen Fahrprofilinformationen mit Beschleunigungen innerhalb eines streckenspezifischen Fahrermodells in Kombination mit historischen und Echtzeit-Verkehrsinformationen berücksichtigt werden. Zweitens müssen veränderte Fahrwiderstandsparameter in das Modell einfließen. Drittens müssen aber auch Wettereinflüsse in Fahrwiderstand und Nebenverbrauch berücksichtigt sein. Hier berechnet [99] jedoch Beschleunigungen nur implizit und nicht strecken- und fahrerspezifisch ein. Zudem bleiben Wettereinflüsse unberücksichtigt. Wie andere Ansätze mit den oben genannten Einflüssen umgehen, erläutern die folgenden Abschnitte 2.2.2 bis 2.2.4.

2.2.2 Fahrzeugeigenschaften

Entsprechend der in 2.1 erläuterten Zusammenhänge, ist der Fahrzeugenergiebedarf abhängig von den Fahrzeugeigenschaften und unter diesen insbesondere von den Fahrwiderständen. Diese setzen viele Modelle konstant an, ohne auf mögliche Änderungen einzugehen. Diese Annahme konstanter Werte erfolgt explizit in den physikalischen Modellen wie z. B. [97; 98; 100; 101; 103] und implizit in allen anderen Modelltypen, wie [1; 71; 78; 80–83; 92; 93]. Unter den nicht physikalischen Modellen sieht nur [66; 88–91] eine Anpassung in Fahrwiderstandsparametern nach dem Anlernen vor. Dagegen nutzen [96; 99] eine kontinuierliche Fahrwiderstandsschätzung, die eine fahrtspezifische

Modelljustierung etwa bei Zuladung oder durch Anbauten, wie einer Dachbox, ermöglicht. Eine Fahrwiderstandsschätzung arbeitet nach dem Prinzip, dass sie kontinuierlich das vom Antrieb gestellte Moment mit einem berechneten der Fahrwiderstandsgleichung vergleicht. Entsprechend der von Messungen verfügbaren Geschwindigkeit, Beschleunigung und Steigung, passen rekursive Algorithmen die Fahrwiderstandsparameter an. Dabei gibt es verschiedenste Verfahren, die [35] zusammenfasst, weiterentwickelt und beurteilt.

Die analysierten Schätzer aus [35] haben verschiedene Eigenschaften, die Abkürzungen zusammenfassen. Hier erfolgt eine grobe Erläuterung der Algorithmen und Abkürzungen, für detailliertere Lektüre sei auf [35] verwiesen. Bei allen Algorithmen handelt es sich um rekursive Regressionen [107, S. 281–283] (RLS oder zweites R), wie von [96] genutzt. Ist der RLS ergänzt um einen Prädiktor-Schritt, zählt dieser zu den Kalman-Filtern (KF) [107, S. 318–327]. Einige Schätzer enthalten eine Levenberg-Marquardt-Regulierung (LMR) [108, S. 594–611] durch Kovarianznormalisierung oder in einer abgewandelten Variante für KF als Stenlund-Gustafsson-Regulierung (SG) [109]. Diese Regulierung vermeidet eine Parameterdrift, wenn in den Schätzer-Inputs zeitweise zu manchen Parametern keine Information vorhanden ist. Ein Beispiel dafür ist die ebene Konstantfahrt ohne Beschleunigungswiderstand und somit keiner Information für die masseabhängigen Fahrwiderstandsparameter. Dabei ist es auch möglich, je nach Parameter und der Häufigkeit eines solchen Informationsmangels, für diesen den Vergessensfaktor individuell anzupassen. Diese in [110] präsentierten multiplen exponentiellen Vergessensfaktoren (mf), legen dabei fest, wie lange ältere Informationen in die Schätzung einfließen. Daneben limitieren einige Schätzer in den Signalen vorhandene Ausreißer abhängig von der kontinuierlich ermittelten Varianz für robustere Schätzungen. Diese sogenannten M-Estimators (M gegen Ende der Abkürzung) [111] tun dies für das Modellausgabesignal, hier das Radmoment. Darüber hinaus beschränkt der Generalisierte-Totale-Kleinste-Quadrate-Schätzer (GTLS) [112] und die Erweiterung um Instrument-Variablen (IV) [113] alle Signale. All diese Schätzer sind robuster gegen systematische Fehler in der Signalmessung. Dagegen kann aber gerade RLS gut mit symmetrischem Gauß-Rauschen umgehen. Die meisten erläuterten Schätzervarianten lassen sich kombinieren,

so nutzt [99] einen SGKF aus [114], um sich ändernde Fahrzeugparameter zu erkennen und in der Energiebedarfsprognose zu berücksichtigen. [35]

Was eine Parameterschätzung jedoch im Fahrzeug nicht erfassen kann, ist eine Berücksichtigung von streckenabhängigen energetischen Wettereinflüssen. Dazu zählen der Wind für den Luftwiderstand und die Temperatur für Roll- und Luftwiderstand entsprechend (2.7)-(2.10). Jedoch ist bisher nur die Luftwiderstandsänderung durch Wind in bekannten Ansätzen berücksichtigt, wie etwa in [96]. Insgesamt gibt es aber noch kein physikalisches Modell, das die Fahrwiderstände anlernt und alle wetterabhängigen Einflüsse erfasst.

2.2.3 Nebenverbraucher

Nicht nur die Fahrwiderstände, sondern auch der Fahrzeugnebenverbrauch sind maßgeblich vom Wetter und insbesondere der Temperatur abhängig, wie 2.1.2 unter Nebenverbraucher erläutert. Manche Modelle vernachlässigen den gesamten Nebenverbrauch [1; 78; 96], setzen fixe Werte an wie [97] oder extrapolieren nur den gerade gemessenen Wert [96]. Dagegen berücksichtigen viele Modelle die Temperaturabhängigkeit [66; 71; 72; 83; 86; 92; 93] oder modellieren ausführlich die Wärmeflüsse [100], wobei hier nur der Kühl- und nicht der Heizfall erfasst ist. Wie in [66] sollte das Modell neben der Umgebungstemperatur auch berücksichtigen, ob der Innenraum bereits die eingestellte Temperatur erreicht hat oder ob diese noch mit Zusatzenergiebedarf einzustellen ist. Allen bekannten Modellen ist gemein, dass sie nur die aktuelle Temperatur einbeziehen. In der Literatur findet sich zwar ein entsprechendes Vorhersagemodell, das Wetterprognosen als Input verwendet, jedoch weist diese Offenlegung keine Genauigkeit oder weitere Modelleigenschaften aus [115]. Dennoch ist ein Nebenverbrauchermodell zu bevorzugen, welches insbesondere den Temperierungsenergiebedarf wetterabhängig basierend auf entsprechenden Vorhersagen entlang der Route vorhersagt.

2.2.4 Fahrprofil

Die Prognose des Fahrprofils, als eine wesentliche Eingangsgröße der Energiebedarfsprognose, muss in der Lage sein, das Zusammenwirken von Fahrer-, Verkehrs- und lokalen Einflüssen auf Geschwindigkeit und insbesondere auch Beschleunigung abzubilden. Modelle wie [1; 78; 80; 83; 92; 103], die den Fahrereinfluss vernachlässigen, können nur eine mittlere Prognose sicherstellen. Manche verwenden zwar eine fahrerspezifische Anpassung des Energiebedarfes entsprechend einem historischen Verbrauchsmittel [66; 86; 101] oder berücksichtigen vom Fahrer gewünschte längs- und querdynamische Grenzen [104], diese Ansätze vernachlässigen jedoch Wechselwirkungen zum Verkehrseinfluss. Dabei kann das Fahrprofilmodell Verkehr in zwei Stufen berücksichtigen. Im ersten Schritt geht der übliche Verkehrseinfluss auf einem Streckenabschnitt abhängig von der Zeit in die Prognose ein, wie in [83]. Das kann z. B. regelmäßigen dichten Pendlerverkehr einfließen lassen. Die zweite Stufe berücksichtigt zusätzlich Echtzeitverkehrsinformationen als Eingangsgröße, wie [98; 99]. Darüber hinaus wäre mit der nicht voraussetzbaren Kenntnis der Ziele aller Verkehrsteilnehmer wie in [100] auch eine aktive Optimierung des energetischen Verkehrseinflusses im Fahrprofil möglich. Das Zusammenspiel von örtlich aufgelöstem Geschwindigkeitsverhalten mit Verkehrs- und Fahrereinfluss modelliert [99] umfassend. Jedoch berücksichtigt diese Fahrprofilprognose, wie in vielen Modellen, zwar ortsaufgelöst Geschwindigkeiten, aber Beschleunigungen fließen nur verallgemeinert ein. So definiert [100] Beschleunigungswerte an Übergangsgeschwindigkeiten und [98] ergänzt dies bei Stoppstellen, welche aus Karteninformation stammen. Mit einer anderen Herangehensweise erweitert [99] dies um verkehrabhängige Aufschläge, aber ohne Ortsabhängigkeit. Auch Machine-Learning-Modelle verwenden verschiedenste verallgemeinerte Beschleunigungseingangsgrößen, wie eine fahrerspezifische Beschleunigungsaggressivität [71] oder nach Vorzeichen der Beschleunigung getrennte Größen [1; 83]. Letzteres soll den Einfluss der Rekuperation gegenüber dem Verbrauch des Fahrzeugvortriebs berücksichtigen, ist aber wegen unterschiedlicher Fahrwiderstände zwischen Fahrzeugen nicht ohne Weiteres übertragbar. Dazu schlägt [103] streckenabschnittsweise leistungsflussabhängige integrale Leistungen vor. Das berücksichtigt zwar korrekt den Energiefluss aufgrund kurzzeitiger Beschleunigung-

en, enthält aber weiterhin fahrzeugabhängige Größen, was die Übertragbarkeit einschränkt. Insbesondere geht [103] aber nicht auf Fahrer- oder Verkehrseinflüsse ein, wie es [99] umfassend tut. Jedoch erfasst [99] Beschleunigungen, wie etwa aus zähflüssigem Verkehr, nicht aufgelöst je Streckenabschnitt in aggregierter Form. Folglich gibt es kein physikalisches Modell, das rein auf Geschwindigkeit und Beschleunigung basierte aggregierte Fahrprofilparameter des zeitlichen Verlaufs verwendet und gleichzeitig umfassend das ortsspezifische Zusammenspiel zwischen Fahrer und Verkehr im energetischen Fahrprofileinfluss erfasst.

2.3 Forschungsfragen

Der Überblick zu bekannten physikalischen Verfahren, die den Fahrzeugenergiebedarf physikalisch prognostizieren, zeigt methodisches Verbesserungspotenzial insbesondere in der nötigen Fahrprofilprognose. So findet sich kein Modell, welches das Fahrprofil zwischen Fahrzeugen übertragbar je Streckenabschnitt aus Flottenfahrprofilen aggregiert und dennoch alle auch kurzzeitigen Beschleunigungseinflüsse berücksichtigt. Da sich kein solches Modell fand, ist auch kein Fahrermodell bekannt, das mit solchen Fahrprofilparametern neben Geschwindigkeits- insbesondere auch Beschleunigungseinflüsse streckenspezifisch lernt und berücksichtigt sowie (Echtzeit-)Verkehrsinformation ergänzt. Folglich liegt der Forschungsschwerpunkt dieser Arbeit in einer Fahrprofilprognose aus Flottendaten für eine physikalische Energiebedarfsprognose, die diesen Anforderungen gerecht wird. Dabei stehen diese drei Forschungsfragen im Mittelpunkt:

1. Wie lässt sich der Verbrauch je Streckenabschnitt einer Karte aus Flottendaten unterschiedlicher Fahrzeugtypen für eine Energiebedarfsprognose charakterisieren?
2. Welche Auswirkungen hat ein Fahrermodell bei der Beschreibung der energetischen Einflüsse?
3. Welche Modellausprägung stellt einen optimalen Kompromiss zwischen Komplexität und Genauigkeit sicher?

Zudem findet sich unter den physikalischen Modellen, welche Flottendaten verwenden, kein Vergleich der präsentierten Ansätze zu anderen bekannten Ansätzen. Daher soll diese Arbeit auch den Vergleich zu anderen flottendaten-gestützten Ansätzen zeigen. Dabei soll eine einheitliche Datenbasis sowohl für Flotten- als auch Testdaten die Vergleichbarkeit sicherstellen. Zusammengefasst ist der Fokus dieser Arbeit eine fahrtspezifische physikalische Energiebedarfsprognose, welche eine strecken-, fahrer- und verkehrsspezifische Fahrprofilprognose basierend auf Flottendaten verschiedenster Fahrzeuge nutzt.

3 Sensitivitäten im Energiebedarf

Entsprechend der in 2.1 erläuterten Wirkzusammenhänge quantifiziert die folgende Sensitivitätsanalyse die Relevanz der Einflüsse auf den Energiebedarf eines Elektrofahrzeugs im Straßenverkehr. Dabei liegt der Fokus auf einer repräsentativen Identifikation der größtmöglichen energetischen Einzelabweichungen im Straßenverkehr mit den Fahrprofildaten aus Nutzerstudien aus 3.3.

Diese Abweichungen beschreiben bisherige Analysen nur eingeschränkt repräsentativ bzw. selektiv für einzelne Einflüsse. So untersuchen [116] und [117] den Strecken- und Fahrereinfluss nur auf einem Rundkurs und unterscheiden etwa Fahrzeugeinflüsse nur recht grob. Die Sensitivitätsbetrachtungen in [66, S. 36 ff.], [114] und [118] differenzieren den Fahrwiderstand zwar weiter, jedoch analysieren diese keine Wettereinflüsse auf die Fahrwiderstände, die auf der Straße jedoch relevant sein können. Diese Wetterabhängigkeit belegen Parameteränderungen in Roll- [23; 25; 26; 28; 29] und Luftwiderstand [18; 20]. Die Analysen des Wettereinflusses auf den Energiebedarf weisen [27], [66, S. 36 ff.] und [117] nur für die Innenraumtemperierung separat aus. Eine repräsentative Betrachtung der Strecken-, Fahrer- und Fahrzeugeinflüsse auf den Energiebedarf mit Einflüssen von unterschiedlichen Ländern, Straßentypen und Wettereinflüssen, auch auf den Fahrwiderstand, liegt bisher nicht vor.

All diese genannten Einflüsse lassen sich mit dem Fahrprofil, Wetterparametern und energetischen Fahrzeugeigenschaften beschreiben. Die letzten beiden können Variationen in den Fahrwiderständen und den Fahrzeugkomponentenverbräuchen beschreiben. Dazu definiert 3.1 zunächst die zu betrachtenden Bandbreiten relevanter Einflüsse im Straßenbetrieb, die die Untersuchung jeweils als Einzeleinfluss analysiert. Diese Einflüsse bildet das in 3.2 erläuterte Modell ab. Dabei beschreibt das Fahrprofil die energetische Variation durch den Fahrer-, Verkehrs- und Streckeneinfluss. Die genutzten Fahrprofildaten aus Nutzerstudien mit verschiedener Szenarien beschreibt 3.3. Dabei ist das

Ziel repräsentative, nach Weltregionen und Straßentypen aufgelöste Ergebnisse zu ermöglichen. Darauf basierend untersucht die Sensitivitätsanalyse die Auswirkung der Einzelparametervariationen auf den elektrischen Fahrzeugenergiebedarf. Diese Einzelparametervariation vernachlässigt mögliche Wechselwirkungen in der Energiebedarfsbetrachtung, wie z. B. von Wind und Niederschlag auf die gefahrene Geschwindigkeit. In einer weiterführenden Analyse könnten diese in erster Näherung über Superposition der Einzeleinflüsse ermittelt werden. Jedoch ist hier die Fragestellung, wie genau das im Folgenden erläuterte Modell die Einzeleinflüsse abbilden sollte, daher wird von einer Korrelationsanalyse abgesehen. Demzufolge arbeitet 3.5 die relevanten Einflüsse heraus, entsprechend derer das ab Kapitel 4 entwickelte Modell der Energiebedarfsprognose die einzelnen Einflüsse detailliert oder auch vereinfacht berücksichtigt.

3.1 Einflussgrößen

Die für Elektrofahrzeuge bereits in 2.1 beschriebene energetischen Einflussparameter aus Fahrwiderstand und Nebenverbrauchern sowie Strecken- und Fahreinflüssen sammelt Tab. 3.1. Diese v. a. aus der Literatur stammenden Parameter sind Eingangsgröße für die Verbrauchsmodelle, siehe 3.2, der Sensitivitätsanalyse basierend auf Fahrprofilaten aus Nutzerstudien entsprechend 3.3. Als Basis der Bewertung dienen Fahrzeug- und Umgebungsparameter des BMW i3 bei einem Zulassungszyklustest unter Normalbedingung [119], welche in Tab. 3.1 unterstrichen sind. Davon abweichend gibt Tab. 3.1 relative Parameterveränderungen je Szenario im Straßenbetrieb an, welche das Modell aus 3.2 einzeln variiert. Dabei berücksichtigen die Nutzungsszenarien bezüglich des Luftwiderstandes sowohl Veränderungen der Fahrzeugoberflächen [20, S. 334–370] als auch Wettereinflüsse durch eine veränderte Luftdichte ρ_L oder Wind [20, S. 394]. Die Rollwiderstandsvariation erfasst neben Temperatur [23, S. 47–48] und Niederschlag [28, S. 85] auch verschiedene Strecken mit unterschiedlichen Straßenrauigkeiten [15, S. 140]. Darüber hinaus schließen die Szenarien der Rollwiderstandsvariation auch den durch den Fahrer beeinflussbaren Reifendruck [28, S. 69] und die Geschwindigkeit [13, S. 16; 18, S. 13; 23, S. 12; 26, S. 86; 28, S. 125; 34, S. 597] ein. Wobei Tab. 3.1 je

Geschwindigkeit die gesamte Bandbreite an Rollwiderstandsänderungen aus der Literatur angibt, die sich über verschiedenen Reifentypen und Testmethoden mit teils konstant gehaltenem Reifendruck ergeben. Für die Bewertung der größten Verbrauchseinflüsse wird die maximale Rollwiderstandsveränderung verwendet. Beim Fahrzeuggebrauch kann der Nutzer ebenso die Zuladung zwischen Leergewicht und zulässigem Gesamtgewicht variieren. Der Energiebedarf der Temperierung hängt zwar auch von den Nutzereinstellungen ab, ist aber vielmehr von der Umgebungstemperatur abhängig, wie Abb. 3.1 entsprechend BMW-internen Messungen zeigt [120, S. 27]. Dabei betrachten die Szenarien je einen Kalt- und Heißfall bezogen auf die geringste Temperierungsleistung bei 20°C. Daneben sind, wie in 2.1.2 erläutert, auch andere Nebenverbraucher zu berücksichtigen. Hier schließen die Nutzungsfälle neben der üblichen Grundlast eine angenommene Verdoppelung resultierend aus parallelen Verbrauchsanforderungen ein. Alle bisher genannten Einflussgrößen der Analyse haben einen Fahrzeugbezug, welche sich mit Parametervariationen erfassen lassen. Daneben soll die Analyse entsprechend der letzten drei Zeilen in Tab. 3.1. Straßentyps, Regions- sowie Verkehrs- und Fahrereinflüsse erfassen, was nur mit verschiedenen Fahrprofilen möglich ist, welche 3.3 näher beschreibt.

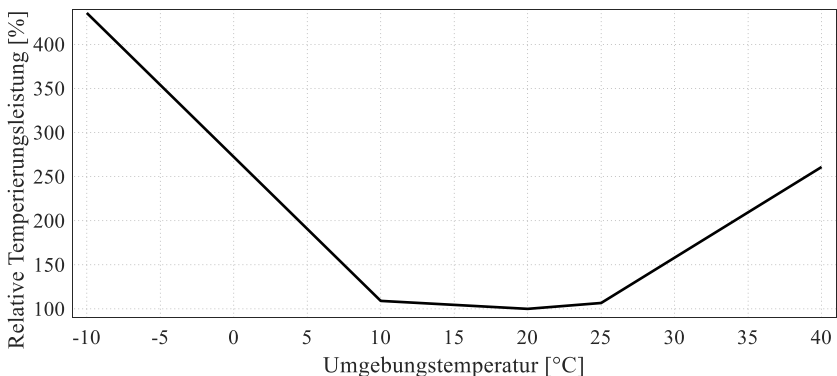


Abb. 3.1: Leistungsbedarf der Temperierung bezogen auf Minimalwert [120, S. 27]

Dazu nutzt die Quantifizierung des Fahrereinflusses Fahrprofilaten von verschiedenen Fahrern auf einer einzelnen Strecke. Dabei schränkt auch Verkehr das Fahrerverhalten ein. Zur weiteren Analyse solcher Streckeneinflüsse unterscheidet die Analyse drei verschiedene Regionen und die Straßentypen inner- oder außerorts. Die Beschreibung der Datengrundlage zur Analyse der verschiedenen Strecken- und Fahrereinflüsse erfolgt im Abschnitt 3.3.

3.2 Energiebedarfsberechnung verschiedener Fahrprofilatentypen

Entsprechend 2.1 können Parameterveränderungen der Fahrzeugkomponenten nicht alle Einflüsse modellieren. Dazu sind verschiedene Fahrprofilaten notwendig. Gerade Fahrer- und Streckenunterschiede lassen sich nur über eine geeignete Wahl des Fahrprofilatentyps erfassen, wobei Fahrprofil Beschleunigungen und Geschwindigkeiten zusammengefasst meint. Diese Arbeit nutzt zwei Fahrprofilatentypen, den Fahrprofilverlauf über die Zeit einer konkreten Einzelfahrt sowie ein Kollektiv von Fahrprofilen. Im Folgenden wird Letzteres Dynamikkollektiv genannt. Dieses erfasst in zeitlichen Anteilen, wie lange sich ein Fahrzeug in einem diskreten Betriebspunktbereich befindet. Dies entspricht einer empirischen Wahrscheinlichkeitsverteilungsfunktion $\tilde{W}_{v,a}$ des Auftretens von Betriebspunktbereichen. Diese diskreten Bereiche definieren Grenzen der Geschwindigkeit v_i und der Beschleunigung a_k . Dagegen ist das Fahrprofil bei einer einzelnen Fahrt kontinuierlich über die Zeit erfasst. Die folgenden beiden Abschnitte erläutern die Energiebedarfsrechnung in kontinuierlicher gefolgt von einer mit Dynamikkollektiven in quasistationärer Form.

3.2.1 Kontinuierlich

Insbesondere für die nach Tab. 3.1 instationären Einflüsse ist eine kontinuierliche Berechnung des Energiebedarfes notwendig. Diese wird für die energetische Analyse von Aufheiz- oder Abkühlphase des Innenraumes und der sich aufwärmenden Reifen zu Fahrtbeginn benötigt. Für in 3.3 gewählte Einzelfahrten mit repräsentativen Streckenanteilen erfolgt die kontinuierliche Berechnung mit dem detaillierten energetischen Fahrzeugmodell [122, S. 103–104], wie in der Validierung.

3.2.2 Quasistationär

Daneben ist eine Gesamtenergiebedarfsrechnung für ein oder mehrere Fahrprofile auch über ein Kollektiv möglich [66, S. 51]. Dabei kann eine Einzelfahrt stationäre und instationäre, also über eine Fahrt auftretende Parameterveränderung abbilden. Eine einzelne Fahrt betrachtet jedoch nur einen sehr konkreten Nutzungsfall. Das kann nur eingeschränkt repräsentativ für eine Grundgesamtheit sein. Dagegen fasst das Dynamikkollektiv Fahrten repräsentativ zusammen. Damit kann es sowohl eine große Datenbasis, entsprechend 3.3, über verschiedene Länder und Straßentypen zusammenfassen als auch differenzieren. Letzteres geht insbesondere auch für einzelne Fahrer. Jedoch können so nur stationäre oder quasistationäre Effekte abgebildet werden. Dabei sind quasistationäre Effekte solche, bei denen der beschreibende Parameterwert innerhalb eines Betriebspunktbereiches des unten detailliert erläuterten Dynamikkollektives und/oder einem auszuwertenden Straßenabschnitt quasi konstant ist. So ist z. B. der Rollwiderstandskoeffizient nach der Aufwärmphase der Reifen in einem Geschwindigkeitsbereich des Dynamikkollektivs quasi konstant [23, S. 12; 34, S. 597]. Entsprechend der Einordnung in Tab. 3.1 sind die Mehrheit der Einflüsse quasi- oder stationär. Damit sind diese bezüglich der Relevanz für den Fahrzeugenergiebedarf mit dem repräsentativeren Fahrprofilatentyp der Dynamikkollektive beurteilbar. Die Energiebedarfsrechnung mit Dynamikkollektiven in favorisierter quasistationärer Art erläutert der folgende Abschnitt.

Der Startpunkt für die Energiebedarfsrechnung zur Beurteilung von quasistationären, aber auch stationären energetischen Einflüssen ist ein Dynamikkollektiv $\tilde{W}_{v,a}$. Dabei lässt sich die Batterieklemmenleistung P_{HVB} für einen Betriebspunkt repräsentativ annehmen, die für die Mittelwerte der Grenzwerte seines Geschwindigkeits- i und Beschleunigungsbereiches k gilt. Diese Leistung lässt sich mit (3.1) ermitteln, nach Kapitel 2.1 mit Antriebswirkungsgradkennfeldern und insbesondere nach (2.15), was über alle Betriebspunkte hinweg das Leistungskennfeld $P_{\text{HVB}}(v, a)$ ergibt. Dabei kann die Variation der fahrzeug- und wetterbezogenen Einflussparameter entsprechend Tab. 3.1 verschiedene Nutzungsszenarien abbilden. Eine mittlere für dieses Dynamikkollektiv repräsentative Klemmenleistungsabnahme \bar{P}_{HVB} ergibt sich nach (3.2). [66, S. 51]

$$P_{\text{HVB}}(v, a)[i, k] = P_{\text{HVB}}\left(\frac{v_i + v_{i+1}}{2}, \frac{a_k + a_{k+1}}{2}\right) \quad (3.1)$$

$$\bar{P}_{\text{HVB}} = \sum_i \sum_k P_{\text{HVB}}[i, k] \cdot \tilde{W}_{v,a}(v_i, a_k) \quad (3.2)$$

$$\bar{v} = \sum_i \frac{v_i + v_{i+1}}{2} \cdot \sum_k \tilde{W}_{v,a}(v_i, a_k) \quad (3.3)$$

$$\bar{E}_{\text{HVB, spez}} = \frac{\bar{E}_{\text{HVB}}}{\Delta t} \cdot \frac{\Delta t}{\Delta s} = \frac{\bar{P}_{\text{HVB}}}{\bar{v}} \quad (3.4)$$

Aus der repräsentativen mittleren Leistung ermittelt (3.4) einen charakteristischen streckenspezifischen Energiebedarf zusammen mit der mittlere Geschwindigkeit \bar{v} . Mit (3.3) lässt sich \bar{v} ermitteln, jedoch erst nach Aufsummieren über alle zugehörigen Beschleunigungshäufigkeiten. Mit dem beschriebenen Vorgehen lassen sich für repräsentative Fahrprofiladaten in Dynamikkollektiven die Auswirkungen der in Tab. 3.1 beschriebenen (quasi-)stationären energetischen Einflüsse auf ein Elektrofahrzeug über eine breite Datenbasis analysieren.

Aufgrund der Annahmen in diesem Vorgehen, bedarf es einer Validierung des energetischen Fahrzeugmodells, wie auch in [122, S. 103–104]. Dazu vergleicht die Validierung für die Artemis-Zyklen High-Way, Road und Urban

[123, S. 82] Berechnungen mit dem Kennfeldansatz und einem energetischen Gesamtfahrzeugmodell des BMW i3. Letzteres ist eine exakte energetische Beschreibung des Fahrzeuges und des Antriebsstranges [122, S. 103–104]. Die Validierung zeigt für die drei Zyklen, dass der kollektivbasierte Ansatz lediglich Abweichungen von -2 bis + 5 % aufweist. Die Abweichungen sind im dynamischeren Stadtzyklus größer, was an der Diskretisierung der Beschleunigung und der dadurch vereinfachten Abbildung im Kollektiv liegt. Insbesondere für relative Vergleiche zwischen verschiedenen Fahrzeugparametrierungen ist diese Genauigkeit ausreichend. Allerdings muss die Interpretation bei geringen Unterschieden diese Unschärfe berücksichtigen. Die beiden beschriebenen Herangehensweisen können die Auswirkung aller in Tab. 3.1 aufgeführten energetischen Einflüsse auf den Fahrzeugenergiebedarf analysieren.

3.3 Datengrundlage

Dieser Abschnitt beschreibt die Wahl der Datengrundlage, auf der die Szenarien der Sensitivitätsanalyse basieren. Bis auf die instationären Phasen können alle Analysen der Einflüsse in Tab. 3.1 (quasi-)stationär erfolgen und sich auf eine große in Dynamikkollektiven erfasste Datenbasis stützen. Dazu erläutert der folgende Abschnitt zunächst die Datenbasis, die für die Analyse aller (quasi-)stationären Einflüsse verwendet werden kann, bis auf den Sonderfall des Fahrer- und Verkehrseinflusses. Die Erläuterung dessen Datengrundlage und die der instationären Einflüsse folgt im Anschluss.

Tab. 3.2: Fahrprofilaten der Dynamikkollektive

Region	Fahreranzahl	Fahrtanzahl	Gesamtstrecke
China	18	17 311	153 752 <i>km</i>
Deutschland	12	6 752	65 642 <i>km</i>
Vereinigte Staaten von Amerika (USA)	13	10 365	116 754 <i>km</i>
Gesamt	43	34 428	336 148 <i>km</i>

Die Fahrprofilatengrundlage der Dynamikkollektive und deren Gruppen fasst Tab. 3.2 zusammen. Die Daten, die auch [122] für Analysen verwendet und

genauer beschreibt, sind hier begrenzt auf dem BMW i3 ähnliche BMW der 3er-Serie. Sie stammen aus mehrmonatigen Datenaufzeichnungen von 43 Freiwilligen auf drei Kontinenten, die so nur für konventionelle und nicht für elektrische Fahrzeuge vergleichbar verfügbar waren. Die vorherige repräsentative Fahrerauswahl erfolgte über eine Befragung zum Nutzungsverhalten. Die danach aufgezeichneten Felddaten ermöglichen energetische Untersuchung für verschiedene Weltregionen. Darüber hinaus sind die Daten für differenziertere Analysen auch nach innerorts und außerorts gefahrenen Strecken unterteilt. In der Sensitivitätsanalyse erlauben die 336 148 km Fahrprofilaten eine repräsentative Bewertung der energetischen Einflüsse, insbesondere unter Berücksichtigung von regionalen Unterschieden im kleinen und großen Maßstab.

Der Fahrer- und Verkehrseinfluss ist nicht mit Dynamikkollektiven erfassbar. Hier ist eine einzelne Strecke für eine Analyse ohne den Einfluss verschiedener Strecken notwendig. Fahrprofilaten einer Strecke enthalten die in 6.1.1 genauer beschriebenen Daten. Der Autobahnabschnitt der A92 von der Auffahrt Erding bis zum Kreuz Neufahrn mit der A9 dient hier als Analysestrecke. Dieser Streckenabschnitt enthält unbeschränkte Bereiche, wo der Fahrereinfluss den größten Freiraum hat. Daneben ist hier auch mit vielen verschiedenen Verkehrsbedingungen zu rechnen, verursacht durch Pendlerverkehr nach München und Rückstau am nachfolgenden Autobahnkreuz. Die Daten aus 6.1.1 beinhalten 11 003 Fahrten von BMW-Fahrzeugen mit aus Datenschutzgründen unbekannter Modellart genau auf der beschriebenen 13 km langen Strecke. Ein aus jeder dieser Fahrten erstelltes Dynamikkollektiv repräsentiert ein Fahrerverhalten. Eine vergleichende energetische Analyse dieser Kollektive ermöglicht die Beurteilung des Fahrer- und Verkehrseinfluss.

Die Beurteilung der Relevanz der instationären energetischen Einflüsse ist nur mit möglichst repräsentativen Einzelfahrten möglich. Dazu dienen zwei Fahrten der in 4.4.4 genauer beschriebenen Daten. Diese Fahrten stammen von einer 67 km langen Strecke mit einer Straßentypaufteilung, gewählt entsprechend dem repräsentativen Artemiszyklus [123, S. 80]. Das aufgezeichnete Fahrprofil ermöglicht eine Abschätzung der energetischen Relevanz der instationären Einflüsse mit den Einzelfahrten mit repräsentativen Streckenanteilen.

3.4 Parametersensitivitäten

Für die in Tab. 3.1 gelisteten Einflüsse im Straßenbetrieb fasst Abb. 3.2 die resultierende Variationsbreite im Energiebedarf in Gruppen zusammen. Dabei zeigt Abb. 3.2 für die Kategorien (1) bis (5) die Szenarien mit minimalem, maximalem und mittlerem Energiebedarf über alle einzeln bewerteten Stützstellen. Diese sind als relative Abweichung von der in 3.1 definierten Referenzbedatung dargestellt. Die Kategorie Fahrer- und Verkehrseinfluss (6) zeigt mit $-38,8$ bis $+71,2$ % die Verbrauchsbandbreite über 95 % der Fahrten und der Median ist der Referenzwert. Hier zeigt sich eine größere Schwankung als die in [116, S. 52] ausgewiesenen -16 bis $+24$ % für den Fahrereinfluss oder die -24 bis $+39$ % in [66, S. 37] für den Stadtbetrieb. Das liegt an, in dieser Arbeit zusätzlich erfassten, Verkehrseinflüssen und deren größerer Schwankungsbreite auf der Autobahn. Der Referenzwert des Straßentypeneinflusses (7) ist der mittlere Energiebedarf in einer Weltregion gemittelt zwischen inner- und außerorts. Damit ist die gezeigte Verbrauchsbandbreite des Straßentypeneinflusses die Differenz zwischen dem mittleren Verbrauch inner- und außerorts. Hier zeigt sich die größte Schwankung mit $\pm 21,9$ % für die deutschen Dynamikkollektive, was der Größenordnung in [116, S. 54] entspricht. Die Bewertung der quasistationären Szenarien von (1) bis (5) beinhaltet jeweils eine Variation über alle drei Länder und die beiden Straßentypen hinweg. Dementsprechend zeigt Abb. 3.2 immer die Extremfälle aus Straßentyp und Land.

In der ersten Gruppe der fahrzeugbezogenen Verbrauchseinflüsse in Abb. 3.2, dem Luftwiderstand ohne Anhänger (1a) tritt die höchste Verbrauchsüberhöhung auf. Diese liegt außerorts für Deutschland bei $+39,1$ %, wenn ein Fahrrad auf dem Dach montiert ist. Das erhöht sich auf $+150,5$ %, wenn hypothetisch außerorts in den USA ein Anhänger (1b) angehängt ist. Hier sind die gefahrenen Geschwindigkeiten, welche quadratisch in den Luftwiderstand eingehen, auch mit einer 100 km/h Limitierung für den Anhängerbetrieb im Schnitt am höchsten. Die größte Verbrauchsminderung im Luftwiderstand (1a) verursacht starker Rückenwind mit bis zu $-20,3$ % insbesondere außerorts. Dagegen ergibt sich bei gleich starkem Wind in Gegenrichtung außerorts die höchste windbedingte Verbrauchssteigerung von $+25,5$ %. Ein weiterer durch Luftwiderstand verursachter Einfluss von etwas geringerer Größe als die bisher

Genannt, ist der durch Luftdichteänderungen. Zwischen einer Luftdichte entsprechend 800 hPa bei 40 °C und 1100 hPa bei –20 °C zeigt sich ein Verbrauchseinfluss von –16,6 % bis +16,7 % für Fahrten außerorts in Deutschland. Das ist eine größere Spannweite als die des Gewichtseinflusses (3).

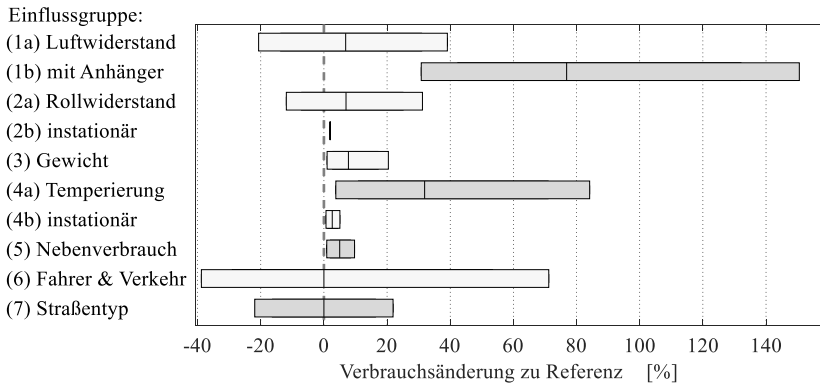


Abb. 3.2: Energiebedarfsänderung durch Einflüsse im Straßenbetrieb

Auch die Rollwiderstandsänderungen (2a) führen zu Verbrauchsminderung und -erhöhung mit –11,9 % bis +31,2 %. Hierbei bewirkt v. a. weicherer Gummi in der Reifenschulter bei 30 °C Umgebungstemperatur diese Verbrauchsminderung innerorts in Deutschland. Ebenfalls für Deutschland, aber außerorts führt ein 1 mm Wasserfilm auf der Straße zur größten Verbrauchserhöhung. Diese Erhöhung im Rollwiderstand verursachen die Wasserverdrängung und der gekühlte, damit stärker dämpfende Gummi. Hier sind wieder die höheren Geschwindigkeiten ausschlaggebend, da der Nässeinfluss mit diesen überproportional steigt. Bezüglich der energetischen Relevanz einer Fahrt mit oder ohne Aufwärmphase der Reifen, ist der Unterschied für die beiden instationär (2b) analysierten Fahrten mit höchstens 2,1 % recht klein. Die Relevanz steigt zwar für kürzere Fahrten, ist aber insbesondere für längere Fahrten, die im Fokus dieser Arbeit sind, eher kleiner.

Etwas mehr Relevanz hat die Gewichtserhöhung (3) bis zum zulässigen Gesamtgewicht. Diese verursacht einen Mehrverbrauch von bis zu 20,4 %

innerorts in den USA. Hier finden besonders viele Beschleunigungen und Verzögerungen statt. Ebenfalls innerorts, aber in China, zeigt sich der größte Temperaturmehrerbrauch (4a) mit +84,2 % im untersuchten Heizfall. Hier begünstigt die im Dynamikkollektiv erfasste geringe mittlere Geschwindigkeit von 21,7 km/h besonders die Relevanz dieses zeitabhängigen Einflusses. Die instationäre Heizphase ist für die beiden typischen Fahrten am relevantesten, aber mit +5,1 % Verbrauchseinfluss nachrangig, was sich für diesen Einmalaufwand mit längerer Fahrt weiter reduziert. Der erhöhte zeitabhängige Nebenverbrauch (5) resultiert mit +9,7 % wie für die Temperierung auch innerorts in China mit dem größten Zusatzenergiebedarf pro Strecke.

Zusammengefasst für die fahrzeugbezogenen Einflussgruppen (1) bis (5) zeigt sich der größte Mehrverbrauch, zunächst für einen Anhängerbetrieb außerorts. Auch ohne Anhänger ist unter den Fahrwiderstandsgrößen der erhöhte Luftwiderstand mit einem Fahrrad auf dem Dach gerade außerorts am größten. Nach den Einflüssen durch nutzerinduzierte Fahrzeugveränderungen sind die Wettereinflüsse am größten. Unter den Fahrwiderstandseinflüssen ist der durch Nässe erhöhte Rollwiderstand gerade bei schneller Fahrt und für das gesamte Fahrzeug der Klimatisierungsenergiebedarf am relevantesten. Das deckt sich qualitativ auch mit den Resultaten in [118, S. 194]. Im Vergleich zu [66, S. 37] ist die Verbrauchsbandbreite der Beladungsszenarien ähnlich. Dagegen sind in [66, S. 37] die Bandbreiten für die Luftwiderstands- und Reifeneinflüsse kleiner, wegen nicht berücksichtigter extremer Geschwindigkeitsszenarien des untersuchten Stadtszenarios. Zuletzt lässt sich bemerken, dass die fahrzeugbezogenen und die strecken-, fahrer- bzw. verkehrsbezogenen Einflussgruppen ähnliche Größenordnungen an Verbrauchsschwankungen hervorrufen.

3.5 Identifikation Parameterrelevanz

Basierend auf den umfassenden Analyseergebnissen energetischer Einfluss-szenarien, lässt sich deren Relevanz für das Prognosemodell des Energiebedarfs im Straßenbetrieb ableiten. Dabei sind die relevanten Dimensionen mit verschiedenen, auch internationalen, Streckentypen, Fahrern, Verkehrssituationen neben Einflüssen am Fahrzeug durch Wetter und Nutzung berücksichtigt.

Die in Abb. 3.2 zusammengefassten Ergebnisse zeigen, dass eine Energiebedarfsprognose für längere Routen die instationären Einflüsse in der Temperierung und im Rollwiderstand, die nur zu Fahrtbeginn auftreten, gröber erfassen kann. Diese Einflussgruppen sind aber in quasistationären Fällen am relevantesten unter den Einflüssen ohne Fahrzeugveränderung. Diese muss das Prognosemodell folglich möglichst gut erfassen und berücksichtigen. Da es sich hier gerade auch um wetterbedingte Szenarien handelt, wäre insbesondere eine Wetterprognose als Input für die Energiebedarfsprognose von Vorteil. Fahrzeugveränderungen gerade durch Anbauten, die den Luftwiderstand verändern, sind je nach Nutzer zwar seltener, aber noch einflussreich und sollten daher möglichst rasch erkannt werden und in die Prognose einfließen. Wie in 3.4 abschließend bemerkt haben Streckeneinflüsse, trotz möglicher Mittelungseffekte, sowie Fahrer- als auch Verkehrseinflüsse eine ähnliche Größenordnung, daher sollte das Energiebedarfsmodell diese möglichst fahrtspezifisch berücksichtigen. All die besonders relevant eingestuften (quasi-)stationären Einflüsse sind eine Größenordnung größer als die in der Validierung der Rechenmethode aufgezeigte Unschärfe in 3.2.1. Damit sind die gezogenen Schlüsse zuverlässig.

Zusammengefasst sollte das Modell der Energiebedarfsprognose für wetterbedingte Temperierungs- und Fahrzeugenergiebedarfe eine Wetterberücksichtigung etwa mit einer Wetterprognose beinhalten. Gerade für Änderungen in Letzteren sollte es auch veränderte Fahrwiderstände rasch anlernen können. Diese sind für Elektrofahrzeuge gerade bezüglich Rollwiderstand und Luftwiderstand von großer Relevanz. Darüber hinaus sollte das Modell die energetischen Fahrprofileinflüsse quantifizieren können. Diese sind das Resultat des Fahrerhaltens und des Streckeneinflusses der Route sowie des Verkehrs auf dieser. Folglich ist ein Modell zur Energiebedarfsprognose anzustreben, welches möglichst fahrtspezifisch die Fahrzeugeinflüsse quantifizieren kann, aber insbesondere auf einer Fahrprofilprognose basiert, welche strecken- und fahrerspezifische Einflüsse quantifiziert.

4 Routenenergiebedarfsprognose

Für den Modellaufbau beschreibt dieses Kapitel zunächst die Anforderungen an die Routenenergiebedarfsprognose. Darauf basierend wird im abgeleiteten Modellkonzept der Ablauf der Prognose und nötige Inputgrößen zusammengefasst. Die danach folgende Definition, wie und mit welchen Daten die Einstellung der Teilmodelle und deren Bewertung erfolgt, bereitet die detailliertere Beschreibung der Prognose und seiner Bestandteile vor.

4.1 Anforderungen

Der in den nächsten Abschnitten erfolgende Modellaufbau ist entsprechend den Zielsetzungen aus 1.2 und der in 3 identifizierten relevanten Einflüsse zu gestalten. Diese gliedern sich in den Streckeneinfluss und den Einfluss des entsprechend dem Fahrerverhalten realisierten Fahrprofils, welche zusammen die Basis für den zu berechnenden Fahrzeuenergiebedarf sind. Die Einflüsse dieser Kategorien muss das Energiebedarfsprognosemodell der Zielsetzung folgend separat anlernen und die Zusammenhänge abbilden können.

Die Streckeneinflüsse sind wie in 2.1 beschrieben zunächst die Steigungen entlang der Route, das Wetter und insbesondere das Fahrprofil, das auf der Strecke realisiert werden kann. Eben Letzteres ist entsprechend den Sensitivitäten aus 3.4 energetisch bezüglich Geschwindigkeiten und Beschleunigungen sehr relevant. Dieser Streckeneinfluss lässt sich insbesondere aus Flottendaten beziehen. Da die Prognose auf möglichst vielen Daten basieren soll, aber der Aufwand für Verarbeitung und Transfer mit steigender Datenmenge zunimmt, muss der Modellansatz sparsam im Speicherplatz sein. Dazu muss der Ansatz bezüglich der erfassten Strecken in möglichst lange Abschnitte aggregieren aber dennoch mit wenigen, einfachen Parametern den energetischen Einfluss der Strecke präzise abbilden. Der damit erfasste Einfluss beschreibt, wie sich

die Gesamtheit aller Fahrer auf einem Streckenabschnitt verhält. Dies variiert abhängig vom Verkehrsaufkommen und ist laut der Sensitivitätsanalyse energetisch relevant. Daher müssen die von der Flotteninformation aggregierten Daten zum einen Tageszeiten auflösen, aber auch adaptierbar bezüglich Echtzeitverkehrsinformationen sein. Diese Adaption ist aber auch unter dem Gesichtspunkt des üblichen Fahrerverhaltens innerhalb der Flottengrundgesamtheit zu betrachten und einzuordnen, da die Sensitivitätsanalyse dieses auch als energetisch relevant identifiziert. Da das Fahrerverhalten eine aus Datenschutzperspektive sensitive Information ist, sollte das Konzept bezüglich der Partitionierung der Informationsverarbeitung die Fahrerverhaltensdaten im Fahrzeug halten können und nicht zwangsweise in einem Backendserver verarbeiten müssen. Letztendlich soll ein Teilmodell das Fahrprofil inklusive Geschwindigkeiten und Beschleunigungen in der Energiebedarfsprognose den energetischen Strecken- und Fahrereinfluss erfassen und prognostizieren.

Die prognostizierte Fahrprofilinformation, die einen Streckeneinfluss beschreibt, ist eine Haupteingangsgröße für den Fahrzeugmodellteil der Energiebedarfsprognose. Daneben sind aber auch Wetter und Steigung für den Energiebedarf relevant, wie die Sensitivitätsanalyse gerade für das Wetter zeigt. Daher ist eine Prognose des Wetters aber auch der Steigungsverlauf entlang der vorausliegenden Strecke neben dem Fahrprofilinput für das Fahrzeugmodell notwendig. Dieses Zusammenspiel der Fahrzeug- und Streckeneinflüsse ist die Schnittstelle zwischen fahrzeugunabhängigen Einflüssen und solchen, die auch von der Antriebsart abhängen. Daher ist hier, wie in 1.2 hergeleitet, für die Übertrag- und Nachvollziehbarkeit insbesondere auf eine physikalische Modellierung zu setzen. Damit kann das Fahrzeugmodell basierend auf den Streckendaten flexibel den Antriebsenergiebedarf prognostizieren, was zunächst mit Initialannahmen der Fahrwiderstands- und Fahrzeugparameter erfolgt. Deren fahrtspezifische Änderungen muss das Prognosemodell jedoch möglichst rasch anlernen, da diese entsprechend der Sensitivitätsanalyse energetisch relevant sind. Daneben sollte das Modell auch die wetterabhängige Temperierungsbedarfsänderung im Nebenverbrauch basierend auf einer Wetterprognose ermitteln, um Änderungen entlang der Route zu berücksichtigen. Zusammengefasst ist das Ziel ein Prognosemodell, welches fahrer- und fahrtspezifisch bezüglich Streckeneinflüssen und Fahrzeugeigenschaften den

Energiebedarf präzise vorhersagt, nach möglichst raschem Anlernen dieser Einflüsse aus Fahrzeug- und Flottendaten.

4.2 Konzept

Entsprechend der Zielsetzung in 1.2 und der oben beschriebenen Anforderungen an die Routenenergiebedarfsprognose beschreibt der folgende Abschnitt die nötigen Modellbestandteile, deren Zusammenspiel und räumliche Verortung. Das Modell muss, von oberster Ebene betrachtet, energetische Einflüsse von Strecke, Fahrer und Fahrzeug anlernen, um diese danach zu prognostizieren. Diese Aufteilung stellt Abb. 4.1 über die Trennung in den Lernteil oben und Prognoseteil unten dar. Die für alle Zielfahrzeuge gleichen Streckeninformationen können am effizientesten zentral in einer Backendserverinfrastruktur gesammelt bzw. aus Flottendaten generiert werden. Die davon abhängige Modellierung der Fahrereinflüsse sollte wegen des Datenschutzes im Fahrzeug erfolgen. Dies gilt auch für die Fahrzeugmodellierung, da diese nur für das Zielfahrzeug relevante Daten beinhaltet und der Verbleib im Fahrzeug das zu versendende Datenvolumen reduziert. Die Energieprognose mit dem Fahrzeug- und Fahrermodell ist also im Zielfahrzeug verortet, wobei die Streckeninformation dafür aus einem Backend kommt.

Die energetischen Einflüsse entlang der Strecke müssen Steigungs-, Wetterprognose- und Fahrprofilinformationen enthalten. Die durch Steigungen beschriebene Routentopologie ist in der digitalen Karte, auf der die Routenberechnung basiert, enthalten und somit verfügbar. Im Anhang geht A.1 näher auf die das Straßennetz beschreibende Karte ein. Die Wetterprognosedaten entlang der Strecke benötigt das Fahrzeugmodell zur später genauer beschriebenen Modellierung von verschiedenen Wettereinflüssen. Die über eine Online-Programmierschnittstelle bezogenen Daten beschreibt A.2 genauer. Der letzte, aber möglicherweise relevanteste zu erfassende Streckeneinfluss ist, mit welchen Geschwindigkeiten und Beschleunigungen auf den Streckenabschnitten gefahren werden kann. Die zeitaktuelle realisierbare Geschwindigkeit kann ein Backendserver entsprechend dem Stand der Technik von einem Serviceprovider für Echtzeitverkehrsinformation (RTTI) im Fahrzeug bereitstellen

[124]. Diese stellen aber gerade für Streckenabschnitte, die aktuell keinen besonderen Verkehrseinflüssen unterliegen, keine Information bereit, welche Geschwindigkeitsbandbreite verschiedene Fahrer darauf realisieren. Hier ist insbesondere auf unbeschränkten Autobahnabschnitten aber auch auf Landstraßen der Streckeneinfluss relevant, etwa bezüglich der Einsehbarkeit der Streckenführung. Darüber hinaus erfassen die mittleren Geschwindigkeiten aus der RTTI nicht die energetisch relevanten Beschleunigungen, die streckenspezifisch auftreten können. Diese energetische Fahrprofilinformation sollen Backendserver mit Blick auf den dort üblichen Verkehr zeitaufgelöst von einer Fahrzeugflotte erfassen, wie 6.1 genau erläutert. Diese Fahrprofilinformation soll für verschiedene Zielfahrzeuge normiert sein, was 4.3 herleitet. Zur Vervollständigung der bisherigen energetischen Informationen des Streckeneinflusses zu Steigungen und Wetter, sollen die erfassten Fahrprofildaten die RTTI ergänzen.

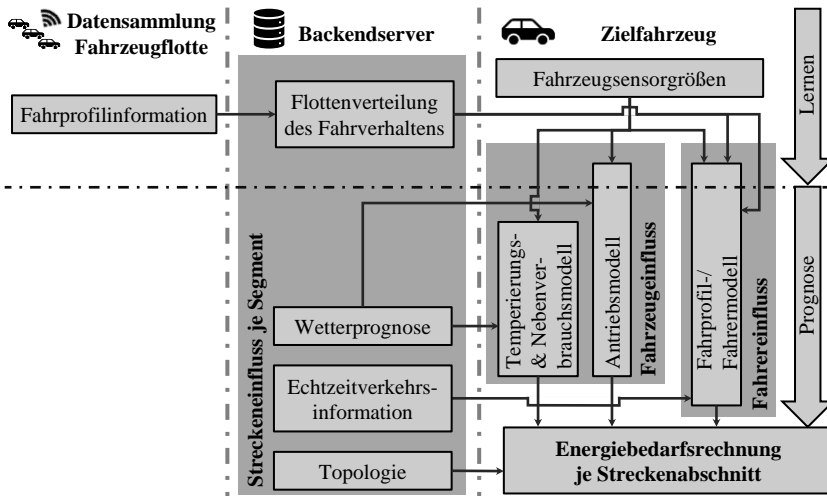


Abb. 4.1: Modellstruktur

Diese flottenbasierten Fahrprofildaten sind die Haupteingangsgröße des Fahrermodells, wie es 6.2 erläutert. Es benötigt die darin erfasste Bandbreite an

verschiedenen Fahrerverhaltensweisen auf einer Strecke. Innerhalb dieser Streuung lernt das Modell mit Sensoren im Zielfahrzeug das Verhalten des Fahrers auf zurückliegenden Strecken an. Also z. B., dass der Fahrer im Erwartungswert schneller als andere fährt. Mit dieser Verhaltensinformation, Fahrprofildaten der geplanten Strecke und Verkehrsinformationen kann das Fahrermodell den zunächst separierten Einflüssen ein erwartetes Fahrprofil für die letztendliche Energiebedarfsprognose ermitteln.

Dieses Fahrprofil wird vom Prognosemodell benötigt, um den Energiebedarf mit den im Fahrzeugmodell erfassten Größen zu berechnen. Das Fahrzeugmodell besteht aus dem Temperierungs- bzw. Nebenverbrauchsmodell und dem Antriebsmodell. Zur Abbildung verschiedener Witterungen nutzt beispielsweise Ersteres zur Bedarfsprognose die Wetterprognosedaten vom Backend zusammen mit im Fahrzeug erfassten und vom Nutzer eingestellten Größen, was 5.2 näher beschreibt. Das Antriebsmodell hingegen lernt entsprechend 5.1 zunächst basierend auf Fahrzeugsensorgößen energetische Parameter, etwa für Luftwiderstandsänderungen durch Anbauten. Diese nutzt das Antriebsmodell zusammen mit Wetterinformation z. B. über Wind zur Bestimmung des Energiebedarfes. Dabei berücksichtigt das Antriebsmodell insbesondere, dass zu starke Verzögerung nicht immer zur Energierückgewinnung nutzbar ist, sondern außerhalb der Antriebssystemgrenzen mechanisches Bremsen notwendig ist. Damit ist das Antriebsmodell der letzte Baustein des Konzeptes zur Prognose des Fahrzeugenergiebedarfes je Streckenabschnitt und quantifiziert die Fahrer-, Strecken- und Fahrzeugeinflüsse umfänglich.

4.3 Trennung fahrzeug- und streckenspezifischer Parameter

Der beschriebene Konzeptansatz benötigt Parameter, die sich innerhalb der Teilmodelle getrennt voneinander verarbeiten und prognostizieren lassen. Dabei ist es insbesondere wichtig, dass die auf Backendservern erfasste, energetische Fahrprofilinformation von verschiedenen Daten sammelnden Fahrzeugen von verschiedenen Zielfahrzeugen zur Energiebedarfsprognose genutzt werden kann. Zudem sollte dies für eine dateneffiziente Übertragung mit we-

nigen und möglichst aggregierten energetischen Parametern gelingen. Dazu leitet dieser Abschnitt eine Trennung der energetischen Fahrzeugparameter von den streckenspezifischen Parametern her. Letztere enthalten Fahrprofil- und Steigungsparameter.

Übernommener Abschnitt: Um den gesamten Energiebedarf einer Strecke zu beschreiben, muss das Modell die Eigenschaften aller Teile des Antriebsstrangs vom Rad bis zur HVB berücksichtigen. Dies ist wesentlich, um ein Routenenergiebedarfsmodell abzuleiten, das für verschiedene Antriebsstränge anwendbar ist. Zur Beschreibung des Energiebedarfs einer Route E_{HVB} (4.1) wird der Energiebedarf entsprechend der Beschreibung in einer digitalen Karte in z Teile $E_{HVB}[j]$ unterteilt. Eine digitale Karte beschreibt das Straßennetz in Streckenabschnitten, indem sie den Straßenabschnitten zwischen den Knotenpunkten des Straßennetzes je mindestens einen Streckenabschnitt zuordnet. Die Diskretisierung des Energiebedarfs entspricht den Streckenabschnittslängen entlang der Route vom ersten bis zum letzten Streckenabschnitt z , die sich der Karte entnehmen lassen. Im Folgenden werden die einzelnen Teilenergiebedarfe $E_{HVB}[j]$ als Streckenabschnittsenergiebedarfe bezeichnet.

$$E_{HVB,z} = \sum_{j=1}^z E_{HVB}[j] \quad (4.1)$$

[Dieser übernommene Abschnitt ist zur Einheitlichkeit dieser Arbeit neuformatiert und übersetzt. © 2022 IEEE. 125, S. 472]___

Entsprechend (2.15) ist der Energiebedarf an der HVB Übernommener Abschnitt: [...] die Summe des Energiebedarfs von Antriebsstrang E_A und Nebenverbrauchern E_{NV} auf jedem Streckenabschnitt $[j]$ vom Start 1 bis zum Ziel z . [...]. Im Folgenden wird (für die Nebenverbraucher; A. d. A.) davon ausgegangen, dass sich diese entlang eines Streckenabschnitts (, welche in der digitalen Karte im Mittel etwa 169 m lang sind,; Anmerkung des Autors (A. d. A.)) quasi-statisch verhalten. Mit anderen Worten, der Leistungsbedarf der Nebenverbraucher P_{NV} ist entlang eines Streckenabschnitts nahezu konstant. Da die Längen der Streckenabschnitte $\Delta s[j]$ aus der digitalen Karte und die mittlere Geschwindigkeit $\bar{v}[j]$ (MG) ebenfalls verfügbar sind, kann die geschätzte Fahrzeit ($\Delta t[j]$; A. d. A.) entlang eines Straßenabschnittes berechnet werden.

Das Produkt dieser Zeit und der $P_{NV}[j]$ ergibt $E_{NV}[j]$ je Streckenabschnitt (, entsprechend (4.2), ; A. d. A.). [*Dieser übernommene Abschnitt ist zur Einheitlichkeit dieser Arbeit neuformatiert und übersetzt.* © CC BY 126 S. 3]___

$$E_{NV}[j] \approx P_{NV}[j] \cdot \Delta t[j] = P_{NV}[j] \cdot \frac{\Delta s[j]}{\bar{v}[j]} \quad (4.2)$$

___*Übernommener Abschnitt:* Dagegen muss für die Berechnung des Antriebsenergiebedarfs zunächst der Radenergiebedarf ermittelt werden. Das Integral der Fahrwiderstandskraft F_{FW} über den Weg s ist der Radenergiebedarf, entsprechend (2.2). Folglich ist der Antriebsenergiebedarf $E_A[j]$ entlang des $[j]$ -ten Streckenabschnitts zwischen seiner Anfangsposition entlang der Gesamtroutenlänge $x[j]$ und dem Anfang des nächsten Streckenabschnitts $x[j + 1]$ das Integral der Radkraft F_{FW} über den Weg s (4.3), unter Berücksichtigung des Wirkungsgrades des Antriebsstrangs η_A entsprechend dem Energiefluss, nach (2.17) [...], wobei die Radkraft- bzw. Fahrwiderstandskrafttrichtung die Energieflussrichtung in der Wirkungsgradberechnung repräsentiert.

$$E_A[j] = \int_{x[j]}^{x[j+1]} \eta_A (F_{FW}) F_{FW}(s) ds \quad (4.3)$$

$$F_{FW}(s) = \mathbf{p}^T \cdot \mathbf{r}(s) = \begin{pmatrix} m_{FZ} \cdot e \\ \frac{\rho_L \cdot c_x \cdot A_x}{2} \\ c_{RW} \cdot m_{FZ} \cdot g \\ m_{FZ} \cdot g \end{pmatrix}^T \cdot \begin{pmatrix} a(s) \\ v^2(s) \\ \cos(\alpha(s)) \\ \sin(\alpha(s)) \end{pmatrix} \quad (4.4)$$

(Entsprechend (4.4) lässt sich die Fahrwiderstandskraft aus (2.1) mit einem Vektorprodukt beschreiben.; A. d. A.). Dabei erfasst der Parametervektor \mathbf{p} die Parameter der jeweiligen Fahrwiderstände. Damit ermöglicht der Vektor \mathbf{p} die Übertragbarkeit auf verschiedene Fahrzeugkonfigurationen, z. B. bezüglich Beladung m_{FZ} . Darüber hinaus kann dieser Einflüsse der Umgebungsbedingungen modellieren, z. B. eine Variation von c_{RW} und ρ_L aufgrund Änderung der Temperatur. Zum anderen bildet der Routenvektor \mathbf{r} den Verlauf der Fahrzeugbeschleunigung a , -geschwindigkeit v sowie der Steigung der Straße α ab.

Für die Ableitung von Kartenattributen aus dem Routenvektor \mathbf{r} wird (hier ebenfalls; A. d. A.), angenommen, dass sich das Problem innerhalb eines Streckenabschnitts quasi-statisch verhält. Dementsprechend wird davon ausgegangen, dass der Parametervektor \mathbf{p} und die Effizienz des Antriebsstrangs η_A innerhalb eines Streckenabschnitts j konstant sind. Mit (4.3) bis (4.4) (und (2.17); A. d. A.) lässt sich der Antriebsstrangenergiebedarf $E_A[j]$ eines Streckenabschnitts mit (4.5) beschreiben. Dabei unterscheidet die Heaviside-Stufenfunktion θ die Effizienzfälle von (2.17) entsprechend der Radkraft- bzw. Fahrwiderstandskraft(, was wie in (2.17) die Indizes für Vortrieb V oder Rekuperation R verdeutlichen; A. d. A.).

$$E_A[j] \approx \mathbf{p}^T[j] \cdot \left\{ \frac{1}{\eta_{A,V}[j]} \int_{x[j]}^{x[j+1]} \theta(F_{FW}(s)) \mathbf{r}(s) ds + \eta_{A,R}[j] \int_{x[j]}^{x[j+1]} \theta(-F_{FW}(s)) \mathbf{r}(s) ds \right\} \quad (4.5)$$

$$\begin{aligned} E_A[j] &\approx \frac{1}{\eta_{A,V}[j]} E_{RD,V}[j] + \eta_{A,R}[j] E_{RD,R}[j] \\ &= \frac{1}{\eta_{A,V}[j]} \mathbf{r}_V[j] \cdot \mathbf{p}^T[j] + \eta_{A,R}[j] \mathbf{r}_R[j] \cdot \mathbf{p}^T[j] \end{aligned} \quad (4.6)$$

$$a_g(s) = -\frac{c_{RW} \cdot \cos(\alpha(s))}{e} - \frac{\rho_L \cdot c_x \cdot A_x}{2 \cdot m_{FZ} \cdot e} v^2(s) - \frac{g \cdot \sin(\alpha(s))}{e} \quad (4.7)$$

Von hier an wird lediglich der sich ändernde Routenvektor \mathbf{r} für Effizienzberücksichtigung geteilt, nicht mehr der Radenergiebedarf $E_{RD}[j]$ selbst. Der Antriebsenergiebedarf jedes Streckenabschnitts $E_A[j]$ lässt sich jedoch immer noch entsprechend (4.6) aus dem separat berechneten Vortriebs- $E_{RD,V}[j]$ und Rekuperationsradenergiebedarf $E_{RD,R}[j]$ berechnen, sofern die einzelnen Radenergiebedarfe anhand eines geteilten Vortriebs- $\mathbf{r}_V[j]$ und Rekuperationsroutenvektors $\mathbf{r}_R[j]$ berechnet werden. Für die Unterscheidung anhand des Fahrprofils selbst, ob eine Fahr-situation eine Vortrieb- oder Rekuperationsphase ist, ist die Radkraft F_{FW} in (4.4) entsprechend der Bedingung (2.17) zu null zu setzen und nach der Beschleunigung aufzulösen. Mit der resultierenden Beschleunigungsschwelle a_g , entsprechend (4.7), lassen sich Rekuperations- und Vortriebsphasen unterscheiden.

Die Aufspaltung des Routenvektors nach Rekuperation und Vortrieb durch eine Beschleunigungsschwelle ermöglicht es, Kartenattribute für und von verschiedenen Antriebsstrangtopologien zu aggregieren. Die Komponenten des Routenvektors \mathbf{r} , die von der Steigung α abhängen, können aus einer statischen Karte entnommen werden, da diese über die Zeit konstant sind. Im Gegensatz dazu sind der Beschleunigungs- und Geschwindigkeitsverlauf stark vom Fahrer und dem typischen Verkehr, aber auch von statischen lokalen Gegebenheiten wie dem Kurvenverlauf abhängig. Dazu beschreiben die integralen Routenvektorkomponenten in Tab. 4.1 das Fahrprofil energetisch losgelöst von den Fahrzeugeigenschaften. Diese werden fortan als energetische Fahrprofil-Kartenattribute (FPKA) bezeichnet. [Dieser übernommene Abschnitt ist zur Einheitlichkeit dieser Arbeit neuformatiert und übersetzt. ©2022 IEEE. 125, S. 472–473]___ Dabei enthält Tab. 4.1 auch die mittlere Geschwindigkeit als FPKA, die entsprechend (4.2) für die rein zeitabhängigen Nebenverbraucher notwendig ist.

Tab. 4.1: Energetische Fahrprofil-Kartenattribute (FPKA) [Diese Tabelle übernommenen und zur Einheitlichkeit dieser Arbeit neuformatiert und übersetzt. © CC BY 126 S. 4]

Fahrprofil Attribute	Vortrieb	Rekuperation
Integrale Beschleunigung (IB)	IBV: $\int [a(s)]_V ds$	IBR: $\int [a(s)]_R ds$
Integrale quadratische Geschwindigkeit (IQG)	IQGV: $\int [v^2(s)]_V ds$	IQGR: $\int [v^2(s)]_R ds$
Mittlere Geschwindigkeit (MG)	\bar{v}	

Diese fünf FPKA ermöglichen auf Fahrprofilebene je Straßenabschnitt die energetischen Einflüsse inklusive aller Beschleunigungs- und Verzögerungsvorgänge entsprechend der Energieflüsse zu erfassen. Dabei sind die FPKA übertragbar auf verschiedene Fahrzeuge mit eigenen Eigenschaften. Einen ähnlichen Ansatz stellt [103] auf Leistungsebene vor, jedoch enthält dieser acht Parameter mit impliziten Fahrwiderstandsparametern statt hier nur fünf Parameter ohne enthaltene Fahrwiderstandsparameter. Damit ist der Ansatz aus [103] nur unter der Annahme von konstanten Fahrwiderstandsparametern ohne Fehler übertragbar, da diese Fahrwiderstandsparameter je nach Fahrt variieren können.

4.4 Bewertungsmethodik

Die folgenden beiden Kapitel 5 und 6 detaillieren zunächst die Teilmodelle des bisher vorgestellten groben Konzeptes der Energiebedarfsprognose. Deren jeweils mögliche Ausprägungen und deren Zusammenspiel im Gesamtkonzept bewertet abschließend 7. Ein Vergleich zu Modellen aus der Literatur rundet die verglichenen Prognosemodelle ab. Für den Vergleich beschreibt dieses Kapitel das Vorgehen der Bewertung hinsichtlich Prognosegenauigkeit und -aufwand. Dazu leitet es auch geeignete Fehlermaße her, die den Vergleich zur abschließend beschriebenen Soll-Datengrundlage quantifizieren sollen. Entsprechend der Forschungsfragen in 2.3 und Anforderungen in 4.1, ist das Ziel dabei, eine genaueste Ausprägung, genannt Vollausprägung, des in 4.2 vorgestellten physikalischen Konzeptes zu entwickeln. Zugleich soll eine alternative methodische Ausprägung entwickelt werden, die mit weniger Aufwand passable Genauigkeit erreicht, hier Paretoausprägung genannt. Diese Benennung lehnt sich an die das Prinzip von Pareto [127] an, welches annimmt, dass mit einem geringen Teil des Aufwandes bereits ein großer Teil einer Aufgabe, hier die Prognosegenauigkeit, erfüllt werden kann. Diese Ausprägungen sollen Literaturmodellen und einem Basismodell gegenübergestellt werden. Dabei ist die Basisausprägung eine, welche sich im Fahrzeugmodell auf fixe Parametrierung entsprechend dem Referenzmodell in 3 stützt.

4.4.1 Vorgehen Ausprägungsdefinition

Die Definition der Konzeptausprägungen benötigt vor einer Gesamtbewertung möglichst getrennte Analysen der Teilmodelle. Dazu gliedert sich die Bewertung in die drei Stufen Fahrzeug-, Fahrprofil- und Gesamtmodellbewertung. Für diese Bewertung stehen entsprechend Abb. 2.3 die umrahmten Größen vom Fahrzeugbus zur Verfügung.

Demnach kann die Bewertung zur Auswahl des Fahrzeugmodelles das aufgezeichnete Sollfahrprofil ohne Fahrprofilprognosefehler als Input für die Berechnungen verwenden. Folglich liefert der Vergleich von Energiebedarfen aus dem Fahrzeugmodell mit dem Sollfahrprofil zum Energiebedarf aus dem Fahrzeugbus zuverlässige Aussagen darüber, wie gut die Fahrzeugmodellteile für

sich sind. Genauso erfolgt der Vergleich der Ergebnisse der Antriebs-, Temperierungs- und Nebenverbrauchermodelle gegenüber dem vom Fahrzeugbus aufgezeichneten Teilsystemenergiebedarfe. Das ermöglicht die Auswahl der Ausprägungen der Fahrzeugteilmodelle für die Voll- und Paretoausprägung.

Die anschließende Auswahl der Fahrprofilmodellausprägungen erfolgt mit einer fixierten Fahrzeugmodellausprägung. Dementsprechend prognostiziert das Fahrprofilmodell in verschiedenen Ausprägungen basierend auf den Flottendaten die Fahrprofilparameter als Input für das fixierte Fahrzeugmodell. Der damit prognostizierte Gesamtenergiebedarf an der HVB-Klemme lässt sich dann mit dem aufgezeichneten Wert vergleichen. Um bei der darauf basierenden Auswahl möglichst gute Aussagen zu generieren, sollte das Fahrzeugmodell möglichst genaue Ergebnisse liefern. Dabei kann sich die Bewertung der Fahrprofilmodellvarianten auf das dann bereits ausgewählte genaueste Fahrzeugmodell, die Vollaussprägung, stützen.

Mit diesen ausgewählten Fahrprofil- und Fahrzeugmodellausprägungen ist die Gesamtmodellbewertung möglich. Diese schließt neben der Voll- und Paretoausprägung auch Modelle aus der Literatur ein. Dabei dient [80] als Vertreter der flottenbasierten Kennfeldmodelle und [1] als einfacher Repräsentant der Machine Learning nutzenden Modelle, welche jeweils auf Flottendaten basieren. Diese Literaturmodelle stützen sich in der Bewertung auf die gleichen Flottendaten zur Aggregation der notwendigen energetischen Fahrprofilparameter. Dies ermöglicht der Bewertung diese Modelle auch auf beliebigen Testrouten zu beurteilen, anders als in [1; 80]. Die Gesamtmodellbewertung vergleicht die Prognosen der Literaturmodelle sowie Voll- und Paretoausprägung mit den in Versuchsfahrten aufgezeichneten Energiebedarfen. Diese Gesamtmodellbewertung ermöglicht eine umfassende Bewertung der Modelle bezüglich der Prognosegüte.

4.4.2 Fehlermaß Genauigkeitsanalyse

Eben diese Bewertung der Prognosegüte benötigt eine Auswahl aussagekräftiger Kriterien für den Vergleich von Modellen. Dabei ist es sowohl wichtig bewerten zu können, ob die Modelle eine systematische Verzerrung im

Prognosewert haben, als auch wie groß die Streuung in den Ergebnissen ist. Dabei sollten die Auswertungen die Auswirkungen von Fehlern bewerten, wenn eine energetisch planende Anwendung aus 1.1 das Modell nutzt und z. B. dem Fahrer darauf basierend eine Reichweite anzeigt. Da ein Fahrer die meiste Zeit eine genaue Anzeige und somit Energiebedarfsprognose benötigt, ist der häufigste entlang einer Fahrt ermittelte Fehler i , also der Medianfehlerwert, zugleich der aussagekräftigste. Diese Fehler ergeben sich aus dem Vergleich des über die Fahrt kumulierten prognostizierten Energiebedarfs $E_{Prognose}$ gegenüber dem aufgezeichneten Energiebedarf E_{soll} am Ende jedes gefahrenen Streckenabschnitts j . Dabei betrachten die Analysen die kumulativen Werte, da diese nicht, wie einzelne Fahrtabschnittsenergiebedarfe, eine Momentaufnahme darstellen, sondern die gesamte Fahrt erfassen. Dieses Vorgehen ist entsprechend einer langfristigen Reichweitenprognose gewählt. Darüber hinaus sind prozentuale Fehler (PE) entsprechend (4.8) zu betrachten, um die Vergleichbarkeit zwischen verschiedenen Fahrten zu gewährleisten. Dabei ist es bei der Abstimmung der Teilmodelle wichtig, dass das aggregierte Fehlermaß zeigen kann, in welche Richtung eine Modellausprägung einen möglichen systematischen Fehler verursacht. Das ermöglicht der prozentuale Medianfehler (MEDPE) über alle z Werte einer Fahrt entsprechend (4.9). Dabei können jedoch Mittelungseffekte auftreten, durch sich ausgleichende positive und negative Fehler in einer Fahrt. Um das zu vermeiden, auch wenn es keine Richtungsinterpretation systematischer Prognosefehler zulässt, müssen zuverlässige Gesamtbewertungen absolute Fehlerwerte verwenden. Dazu nutzen diese Analysen den absoluten prozentualen Medianfehler (MEDAPE) als gesamthaftes Gütekriterium über die Fehlerwerte i entlang einer Fahrt entsprechend (4.10). Die Kennzahlen MEDPE und MEDAPE sind also Größen, die das Ergebnis in den Anwenderfunktionen in geeigneter Weise zusammenfassen und eine zuverlässige Optimierung der Genauigkeit zulassen.

$$PE[i] = \frac{[\sum_{j=1}^i E[j]]_{Prognose} - [\sum_{j=1}^i E[j]]_{soll}}{[\sum_{j=1}^i E[j]]_{soll}} \cdot 100 \% \quad (4.8)$$

$$MEDPE = \overline{\overline{(PE[1], PE[2], \dots, PE[z])}} \quad (4.9)$$

$$\text{MEDAPE} = \overline{(|\text{PE}[1]|, |\text{PE}[2]|, \dots, |\text{PE}[z]|)} \quad (4.10)$$

Die Analysen fassen entsprechend der beispielhaften Abb. 4.2 die Ergebnisse aller Fahrten in Boxplots zusammen, hier für den MEDPE im Antriebsenergiebedarf E_A . Dabei markiert der schwarze vertikale Strich in der Box den Median bzw. das 50 % Perzentil der Stichprobe mit n Fahrten, hier beispielhaft bei 11 %. Entsprechend der Standardabweichung der Stichprobe ergibt sich um den Median ein mit zwei roten Strichen markiertes 95 % Vertrauensintervall. Dieses gibt an, in welchem Bereich der wahre Medianwert mit 95 % Wahrscheinlichkeit liegt. Beim Vergleich zweier Stichproben bedeuten überlappende Vertrauensintervalle, dass kein signifikanter Unterschied zwischen den Medianwerten vorliegt. Umgekehrt zeigen nicht überlappende Vertrauensbereiche, dass der Median für die verglichenen Stichproben signifikant verschieden ist. Die Box um den Median repräsentiert den Interquartilsabstand (IQR), der als ein Streuungsmaß dient. Der IQR beschreibt dabei den Bereich der mittleren 50 % der Fahrten in der Stichprobe. Daran schließen sich zwei Whisker (eng.: Antennen) an, welche entsprechend einer Normalverteilungsannahme den Bereich der mittleren 99,3 % der Fahrten in der Stichprobe begrenzen. Außerhalb dieses Bereiches gelten Ergebnisse als Ausreißer, welche die Abbildung zur besseren Lesbarkeit abschneidet, falls nicht anders angegeben. Die Grenze, ab welcher abgeschnitten wird, markieren vertikale Strichlinien außerhalb der Antennen am Rand der Darstellung. Ergänzend gibt die Darstellung für den Median mit Vertrauensbereich sowie IQR die Werte an. Diese Darstellung ermöglicht über viele Fahrten eine aussagekräftige Analyse der Genauigkeit, welche die Energiebedarfsprognose Anwenderfunktionen bereitstellen kann.




Abb. 4.2: Beispielhafte Darstellung einer Fehlerauswertung

4.4.3 Vorgehen Aufwandsanalyse

Neben der Modellgüte ist für eine Fahrzeugimplementierung auch ausschlaggebend, wie lange die Prognose dauert. Dazu sollen die Modellausprägungen und Literaturmodelle auf die Recheneffizienz überprüft werden. Dabei sollen generelle, auf andere Berechnungshardware übertragbare Aussagen generiert werden. Das ist notwendig, da die Untersuchung nur eine prototypische Hardware und nicht ein Zielsteuergerät nutzt. Folglich erfolgt die Bewertung relativ zu dem Modell, das die längste Zeit zur Prognoseberechnung benötigt. Dabei basiert die Bewertung auf dem Mittel mehrerer Rechenläufe je Modell. Der damit mögliche relative Vergleich ist die Basis für die Abwägung zwischen Aufwand und Rechengenauigkeit und somit für die Entscheidung, welches Modell man für eine Implementierung bevorzugen sollte.

4.4.4 Datengrundlage

Für die oben beschriebenen Analysen dienen Felddaten, aufgezeichnet bei BMW i3-Versuchsfahrten. Dazu fuhren 26 Fahrer bei insgesamt 233 Fahrten 12 265 km ein. Die Energiebedarfsprognose ist entsprechend 1.1 Input für eher langfristig planende Anwendungen. Daher sind die gezeigten Fahrten eine Auswahl von Fahrten mit mehr als 10 km Länge aus einer größeren Felddatengrundgesamtheit. Wie Abb. 4.3 zeigt, fanden die Fahrten rund um Leipzig und München auf verschiedenen Straßentypen mit in der Abbildung gezeigten Streckenanteilen statt. Die Längenverteilung der Fahrten zeigt Abb. 4.4.

Für die Solldatengrundlage zeichneten während der Fahrten Fahrzeugbus-Datenlogger neben den in Abb. 2.3 gezeigten Energie- und Fahrprofilgrößen weitere Informationen auf. Für die spätere Prognose ist, insbesondere zur Nachvollziehbarkeit der Route, die sekundlich aufgezeichnete odometriefusionierte Geoposition wichtig. Diese basiert auf dem amerikanischen Global Positioning System (GPS) und dem russischen Global Navigation Satellite System (GLONASS). Mit der Geoposition kann ein Map-Matching, hier basierend auf einem Hidden Markov Modell [128], die aufgezeichneten Streckenabschnitte der digitalen Karte zuweisen. Damit kann die Prognose jede Fahrt wie mit aktiver Routenführung, also mit bekannter Strecke, behandeln. Dabei

stehen die Echtzeitverkehrsinformationen allerdings ausschließlich mit aktiver Routenführung auf dem Fahrzeugbus für die Aufzeichnung zur Verfügung. Immer verfügbar und aufgezeichnet ist die Straßentypinformation sowie die aktuelle Kurvenkrümmung. Zusätzlich kann die Wetterprognose nach A.2 mit den Geopositionen die Wetterinformationen ergänzen. Neben diesen Streckeninformationen beinhaltet die Fahrtaufzeichnung Fahrzeuginformationen zur Fahrzeugneigung, zum Bremsenstatus, zu Klimaeinstellungen, zur Sitzplatzbelegung, zum HVB Ladestatus (SOC) und falls verbaut, über die Aktivität eines Rangeextenders, jeweils aufgezeichnet über der Zeit.

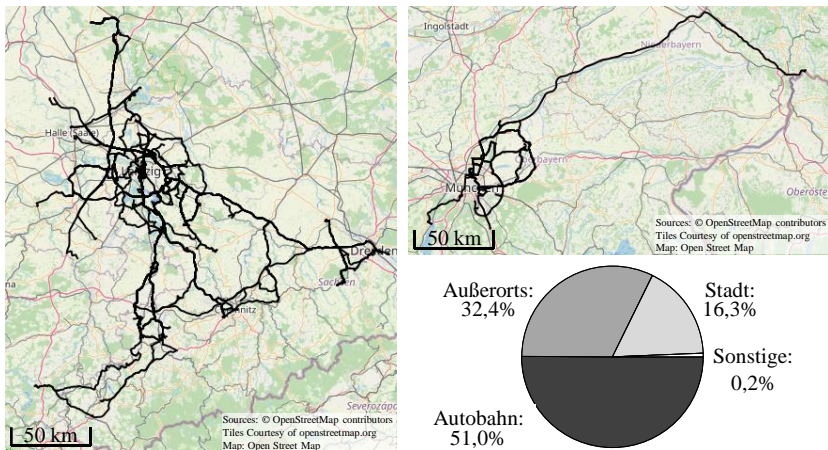


Abb. 4.3: Karte der Versuchsfahrten und deren Streckenanteile nach Straßentyp




Abb. 4.4: Längen der Versuchsfahrten

Die Bewertung der Modelle soll, wie die Sensitivitätsuntersuchung in 3, die Genauigkeit verschiedener Modelle auch bei verschiedenen Straßentypen ermitteln. Dazu lassen sich die in den Aufzeichnungen verfügbaren Straßentypinformationen nutzen. Validierungsgruppen mit Fahrten die sich vorwiegend, was in dieser Arbeit als Streckenanteil größer 60 % gewählt ist, auf einem Straßentyp bewegen, sollen dafür repräsentativ stehen. Die 233 Fahrten enthalten demnach sieben Stadtfahrten, 27 Überlandfahrten und 95 Autobahnfahrten. Die übrigen 101 Fahrten haben keinen mit mehr als 60 % Streckenanteil dominierenden Straßentyp und sind daher keiner Validierungsgruppe zugeordnet und erscheinen nur in der Gesamtanzahl. Die beschriebenen erfassten Daten und eine differenzierte Bewertung in Validierungsgruppen mit ähnlichen Rahmenbedingungen sind die Basis für die zuvor beschriebene eingehende Bewertung der Modelle.

5 Fahrzeugparameterbestimmung

Die Sensitivitätsuntersuchung in 3 zeigt, dass viele Einflüsse auf das Fahrzeug den Energiebedarf relevant beeinflussen. Zur Berücksichtigung dieser Einflüsse erläutert der nachfolgende Abschnitt die Ermittlung der Fahrzeugparameter und -eigenschaften für die Energiebedarfsprognose entlang einer Route, basierend auf der im Kapitel 6 beschriebenen Fahrprofilprognose. Die Erklärung erfolgt separat für das Antriebs- und das Nebenverbrauchsmodell. Deren Beschreibung startet jeweils mit der Methodik und bewertet diese mit der Bewertungsmethodik aus 4.4.1, unabhängig von Fahrprofilprognosefehlern basierend auf dem Sollfahrprofil. Dieses Antriebs- und das Nebenverbrauchermodell sollen die nach 3 für den Energiebedarf relevanten Fahrzeugparameter fahrtspezifisch in der Prognose berücksichtigen.

5.1 Antriebsmodell

Das zweiteilige Antriebsmodell erfasst ausgehend vom Fahrprofil zunächst den Energiebedarf zur Fahrwiderstandsüberwindung und nachfolgend die dabei entstehenden Verluste. Ausgehend vom Rad erläutert das Kapitel erst das lernende Fahrwiderstands- und ergänzende Wettereinflussmodell. Abschließend folgt die Erläuterung der Effizienzmodellvarianten. Nach separater Bewertung je Modell folgt auch solch eine für den Gesamtantriebsstrang mit einem Vergleich zu aus der Literatur bekannten Modellen.

5.1.1 Fahrwiderstand

Entsprechend 2.1 bestimmen die Fahrwiderstände den Antriebsverbrauch des Fahrzeuges und können im Straßenbetrieb stark variieren, wie 3 zeigt. Diese Änderungen soll ein Schätzermodell anlernen. Dies kann aber nur im Mittel über die Fahrt gleichbleibende Werte erfassen. Gerade wetterbedingte Ein-

flüsse variieren aber über die Fahrt, was ein Zusatzmodell basierend auf Wetterprognosedaten berücksichtigt. Nach einer Bewertung wird ein Modell ausgewählt, welches die Basis für das Gesamtantriebsstrangmodell im Zusammenspiel mit dem danach beschriebenen Effizienzmodell ist.

5.1.1.1 Schätzermodell

Zum Lernen der Fahrwiderstandsparameter nutzt die Routenenergiebedarfsprognose Schätzermodelle aus [35], entsprechend 2.2.2. Zwar favorisiert [35] ein Fahrwiderstandsmodell mit vier geschätzten Parametern, das neben den Fahrwiderständen in (2.1) auch die Querdynamik berücksichtigt, kann aber keinen signifikanten, sondern nur einen tendenziellen Vorteil dafür ausweisen [35]. Die Prognose würde den Schwerpunktbahnradius benötigen, der aber wegen der Spurabhängigkeit nicht genau vorhersagbar ist. Zudem könnte die Prognose nur einen Segmentmittelwert des Radius einrechnen, was zu einer weiteren Unschärfe führt. Daher nutzt die Fahrwiderstandsschätzung hier das nicht signifikant schlechtere, aber weniger aufwendige Modell entsprechend (5.1) mit drei Parametern für Massebeschleunigungs-, Luft- und Rollwiderstand [35, S. 114]. Dieses Modell gleicht das nötige Radmoment zur Überwindung der genannten Fahrwiderstände mit den realisierten Geschwindigkeiten v , Beschleunigungen a und Steigungen α ab. Dabei ist das Radmoment aus dem laut 4.4.4 bzw. Abb. 2.3 am Fahrzeugbus verfügbaren Motormoment zu errechnen, das aus dem Motorstrom ermittelt ist. Diese Berechnung muss Getriebewirkungsgrad η_A und -übersetzung $i_{M,RD}$ miteinfassen. Der Getriebewirkungsgrad ist dazu entsprechend dem Betriebspunkt in Motormoment- T_M und -drehzahl ω_M aus einem Kennfeld des Validierungsmodelles in 3.2.1 entnommen. Neben dem Antriebsradmoment berücksichtigt das Momentengleichgewicht am Rad die Fahrwiderstandskraft über den Radradius r_{RD} . Dieses Modell kann die Fahrwiderstände mit in 2.2.2 erläuterten Algorithmen aus den Fahrzeugbussignalen schätzen.

$$\min \left(T_M \cdot \eta_A(T_M, \omega_M)^{\text{sgn}(T_M)} \cdot i_{M,RD} - \begin{bmatrix} a \cdot e + \sin(\alpha) \cdot g \\ v^2 \\ \cos(\alpha) \cdot g \end{bmatrix}^T \begin{bmatrix} m_{FZ} \\ \frac{\rho \cdot c_x \cdot A_x}{2} \\ c_{RW} \cdot m_{FZ} \end{bmatrix} r_{RD} \right) \quad (5.1)$$

Entsprechend [35, S. 101-112] bedürfen die rauschbehafteten Signale des Fahrzeugbus für Geschwindigkeit, der daraus abgeleiteten Beschleunigung, der Steigung und des Motormomentes jedoch zunächst eine Glättung. Dazu nutzt diese den in [112] vorgestellten Polynomial Kalman Smoother (PKS), entsprechend [35]. Dieser legt abschnittsweise Polynome in das Wegsignal. Mit den analytischen Ableitungen dieser Polynome lässt sich neben der Geschwindigkeit auch die Längsbeschleunigung in konsistenter Weise nutzen, hier entsprechend der Umsetzung in [129, betreute Abschlussarbeit] verwendet. Die übrigen Signale kann die Schätzung nach einfacher PKS-Glättung verwenden. Damit kann die Schätzung ab Fahrtstart und bei verfügbaren Signalen erfolgen, solange das verwendete Modell gültig ist. Das ist der Fall bei einer Vorwärtsfahrt mit Geschwindigkeit größer 3 m/s , wenn das Motormoment mindestens $0,4 \text{ Nm}$ beträgt und wenn in den letzten $0,5 \text{ s}$ die mechanische Bremse nicht aktiviert war, was angelehnt an [35, S. 112] gewählt ist. So ist sichergestellt, dass das Momentengleichgewicht am Rad kein Bremsmoment enthält und die Getriebeübersetzung nach Anlegen der Zahnflanken gültig ist. Damit stehen die vorverarbeiteten Signale und das Fahrwiderstandsmodell für die Schätzung bereit.

Für die Auswahl aus den in [35] bzw. 2.2.2 vorgestellten Schätzeralgorithmen nutzt eine Voruntersuchung 13 Fahrten. Dazu ermitteln alle nachfolgend beschriebenen Schätzer die Parameter, analog [129, betreute Abschlussarbeit], wobei dort die Konvergenzzeitpunktwahl zunächst manuell anhand des Parameterverlaufes erfolgt. Die damit parametrisierten Modelle berechnen, basierend auf dem kontinuierlichen Fahrprofil, den Energiebedarf für einen Vergleich mit der Messung. Die Vergleichsergebnisse fasst Abb. 5.1 zusammen, analog [129, betreute Abschlussarbeit].

In Abb. 5.1 zeigen die verschiedenen Regulierungs- und Robustheitsschätzerbestandteile entsprechend 2.2.2 verschieden gute Ergebnisse. Jedoch lässt sich beobachten, dass der RLS ohne diese Bestandteile das im Fehlererwartungswert schlechteste Ergebnis liefert. Besonders auffällig ist, dass die mf-Regulierung die größten Verbesserungen erzielt. Das ist insbesondere für den RLSmf und LMRRIVMmf im Erwartungswert zu beobachten, wobei Letzterer jedoch mehr streut. Der RLSmf hingegen hat unter allen Algorithmen die

kleinste Streuung bei geringstem systematischem Fehler. Darüber hinaus ist der RLSmf gegenüber allen anderen Algorithmen, die ähnlich wenig streuen, signifikant besser bezüglich systematischer Fehler. Daher verwendet die Fahrwiderstandsschätzung für die Energiebedarfsprognose den RLSmf. Hier sei angemerkt, dass [35, S. 128–129] zwar den hier LMRRM genannten Algorithmus favorisiert, was aber für einen 90 s Vorhersagehorizont gilt, statt der hier über die ganze Fahrt notwendigen Bewertung.

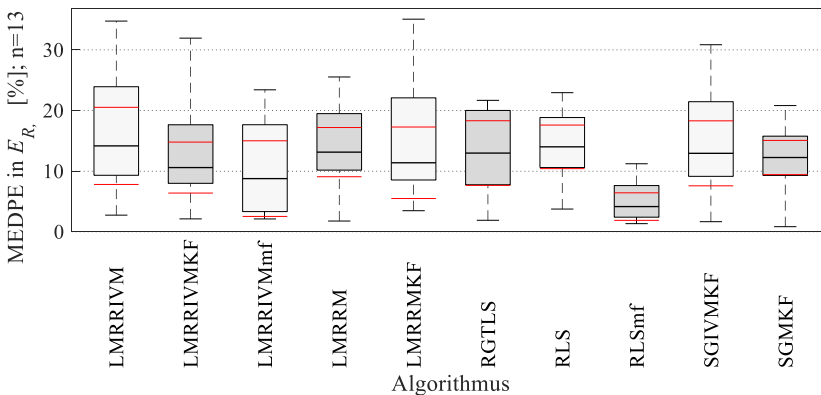


Abb. 5.1: Qualität verschiedener Algorithmen zur Fahrwiderstandsschätzung

5.1.1.2 Konvergenzerkennung Schätzung

Die zuvor gezeigten Analysen basierten auf den Schätzergebnissen mit manueller Konvergenzerkennung, was die Energiebedarfsprognose während der Fahrt automatisiert tun muss. Folglich ist ein Konvergenzkriterium notwendig. Dazu folgt die Erläuterung zweier Methoden zur Konvergenzerkennung aus [129, S. 38–40] und wie diese in der Fahrwiderstandsschätzung verwendet wird. Die Gegenüberstellung der Methoden zur Konvergenzerkennung folgt dann mit den anderen Bewertungsergebnissen zur Fahrwiderstandsschätzung in 5.1.1.5.

Die erste Methode stützt sich auf die Varianzen der geschätzten Parameter, welche rekursive Schätzer kontinuierlich ermitteln. Grundsätzlich verbleibt

wegen Mess- und Modellungenauigkeiten auch nach langem Schätzen immer etwas Varianz. Das Konvergenzkriterium sollte jedoch möglichst die Varianz des Parameters nutzen, welcher am wenigsten Änderungen über die Fahrt erwarten lässt. Gerade der Rollwiderstandsparameter unterliegt vielen Umwelteinflüssen und ist daher, anders als die Parameter von Masse und Luftwiderstand, ungeeignet. Die Parameterverläufe der oben gezeigten Voruntersuchung zeigten zudem, dass – insbesondere mit dem nach 5.1.1.4 berücksichtigten Wind – die Variation in den Luftwiderstandsparametern am geringsten ist. Für diese sinkt die Varianz am zuverlässigsten und ist entsprechend den manuell erkannten Konvergenzen für den RLSmf unter $1.0 \cdot 10^{-10}$ als konvergiert anzunehmen. Die Konvergenzerkennung muss nun nur noch nach jedem Zeitschritt die Varianzen damit vergleichen. Die Schätzung ist als konvergiert anzunehmen, wenn die Varianz den Schwellenwert unterschreitet. [129, betreute Abschlussarbeit, S. 39]

Ähnlich wie die vorherige Methode lässt sich neben einem Schwellenwert in der Varianz auch ab einer gewissen verarbeiteten Informationsmenge bzw. Schätzeranregung erwarten, dass die Schätzung konvergiert. In der Schätzung stellt der Algorithmus entsprechend (5.1) jedem Parameter ein passendes Inputsignal als Information gegenüber. Je mehr dieser Information vorliegt, desto geringer ist die verbleibende Unsicherheit und somit die Varianz. Dem oben verwendeten Schwellenwert für die Varianz im Luftwiderstandsparameter entspricht also die Summe an v^2 -Information, die der Schätzer hat. Dies lässt sich über ein zeitliches Integral verfolgen. Analog zu oben empirisch ermittelt, ist oberhalb eines Wertes von $1.537 \cdot 10^5 \text{ m}^2/\text{s}$ von konvergierten Fahrwiderstandswerten auszugehen. Diese Methode der Konvergenzerkennung über eine Anregungsschwelle macht zwar eine kontinuierliche Summation des Signals notwendig, hat jedoch den Vorteil, dass diese prinzipiell für jeden Algorithmus gleich anwendbar ist. [129, betreute Abschlussarbeit, S. 39-40]

5.1.1.3 Initialannahmen

Ehe nach einer Konvergenzerkennung die Fahrwiderstandswerte aus der Schätzung in die Energiebedarfsprognose einfließen können, muss das Fahrzeug eine gewisse Strecke fahren. Um auch in dieser Phase eine Energiebedarfsprognose zu ermöglichen, bedarf es Initialwerte. Dazu nutzt die Prognose

die Referenzwerte entsprechend 3.1. Zusätzlich passt die Initialisierung das Fahrzeugesamtgewicht schon entsprechend der Gurtbelegung je Passagier um das durchschnittliche Gewicht einer deutschen Person von $77,0\text{ kg}$ an [130, S. 15]. Diese Startwerte ermöglichen eine Prognose ab Fahrtstart.

5.1.1.4 Wetterberücksichtigung

Entsprechend der Einflussanalyse in 3 beeinflusst das Wetter wesentlich den Energiebedarf. So variieren insbesondere Roll- und Luftwiderstand entsprechend den Umgebungsbedingungen, was die Energiebedarfsprognose entsprechend [120, betreute Abschlussarbeit] teils ab Fahrtbeginn berücksichtigt.

Die in Tab. 3.1 gelisteten möglichen Änderungen im Rollwiderstand kann das Antriebsmodell nur für Umgebungstemperaturänderungen explizit berücksichtigen. Diese kann die Prognose mit (2.7) modellieren, da die Wetterprognose aus A.2 die nötige Temperatur liefert [24]. Diese könnte zwar auch Niederschlagsinformationen liefern, aber zur Modellierung dieses Einflusses auf den Rollwiderstand sind weitere Informationen notwendig. Entweder bräuchte das Modell für eine explizite Berücksichtigung zusätzliche Fahrzeugsensoren zum Anlernen oder ein Modell, das die Wasserfilmhöhe auf der Fahrbahnoberfläche bestimmt. Daher nähert die Energiebedarfsprognose in der Initialphase nur den Temperatureinfluss auf den Rollwiderstand explizit an, bis die Fahrwiderstandsschätzung einen möglichen Niederschlagseinfluss für die aktuelle Fahrt implizit angelernt hat. [120, betreute Abschlussarbeit, S. 38–43]

Das Wetter beeinflusst den Luftwiderstand über Luftdichte und Wind. Die Dichte ändert sich mit Umgebungsdruck und -temperatur, was die Prognose für die ganze Fahrt mit (2.10) [20, S. 142; 38] berücksichtigt, basierend auf den Wetterprognosedaten aus A.2. Zudem verändert der Wind die Anströmgeschwindigkeit und bei Windanteilen quer zur Fahrtrichtung auch die Anströmverhältnisse. Letztere lassen sich durch eine Windkanalvermessung berücksichtigen, jedoch nur für ein Fahrzeug ohne Anbauten. Daher inkludiert das Modell die Anströmrichtung in der Initialphase und wenn die Fahrwiderstandsschätzung wenig Abweichungen feststellt. Um darüber hinaus die veränderte Anströmgeschwindigkeit zu berücksichtigen, benötigt das Modell in 4.3 bzw. [125] bestehend aus getrennten Fahrzeug- und Streckenparametern in Letzter-

en eine Anpassung. Dazu muss die Wetteranpassung in (5.2) und (5.3) die originalen mit 0 indizierten, FPKA IQGV und IQGR verändern, die den Einfluss des Luftwiderstands energetisch in den Streckenparametern nur relativ zum Boden erfassen [131, S. 140]. Allerdings liefern diese Streckenparameter mit der in Fahrtrichtung wirkenden Windgeschwindigkeit $v_{Wind,x}$ einen Erwartungswert für diese FPKA. Dieser mit m indizierte modifizierte Wert enthält den Windeinfluss entsprechend der Wetterprognose in A.2. [120, betreute Abschlussarbeit, S. 34–38]

$$\widehat{IQGV}_m = IQGV_0 \cdot \frac{(MG_0 + v_{Wind,x})^2 \cdot \Delta s}{MG_0^2 \cdot \Delta s} \quad (5.2)$$

$$\widehat{IQGR}_m = IQGR_0 \cdot \frac{(MG_0 + v_{Wind,x})^2 \cdot \Delta s}{MG_0^2 \cdot \Delta s} \quad (5.3)$$

Die Fahrwiderstandsschätzung unterliegt ebenso dem Windeinfluss, und zwar so, dass das Modell (5.1) den Einfluss nicht explizit erfasst. Jedoch kann das Wettermodell die Daten für die Ermittlung der veränderten Anströmgeschwindigkeit im Schätzermodell bereitstellen. Das sollte die Güte der Schätzergebnisse weiter steigern.

Mit dem beschriebenen Fahrwiderstandsmodell mit Parameterschätzung und Wetteranpassungen kann die Energiebedarfsprognose strecken- und fahrtspezifische Einflüsse auf die Fahrwiderstände berücksichtigen. Deren Einfluss auf den Antriebsenergiebedarf ist für die Masse, Roll-, und Luftwiderstandsparameter verschieden berücksichtigt. Die Masse ist initial explizit mit sensorbasierter Logik angenähert und fließt nach Konvergenz geschätzt in die Prognose ein. Dagegen erfasst das Modell für den Rollwiderstand initial explizit den Umgebungstemperatureinfluss. Nach erkannter Konvergenz liefert die Fahrwiderstandsschätzung implizit Information über den gemittelten Einfluss von Straßenrauigkeit, Niederschlag, Temperatur als auch Reifendruck oder -wechsel, z. B. zwischen Sommer- und Winterreifen. Dagegen kann die Energiebedarfsprognose außer Anbauten am Fahrzeug alle Einflüsse auf den Luftwiderstand explizit modellieren. Mit diesem letzten Baustein ist das Antriebsmodell

in der Lage, alle relevanten Einflüsse entsprechend den Voranalysen zu deren Sensitivität im Energiebedarf zu berücksichtigen.

5.1.1.5 Ergebnis


Wie genau diese Fahrwiderstandsmodellierung ist, zeigen die folgenden Ergebnisse der Bewertung in der Antriebsenergie E_A entsprechend 4.4. Dazu nutzt das Antriebsmodell die einfache Modellierung der Antriebseffizienz mit den Kennfeldern, die auch 3 nutzt und deren Genauigkeit erst 5.1.2.3 aufzeigt. Zunächst sollen Ergebnisse aus der Gegenüberstellung der beiden Konvergenzmethoden aus 5.1.1.2 in Abb. 5.2 aufzeigen, welche davon zu favorisieren ist. Diese damit eingestellte Fahrwiderstandsschätzung mit und ohne Wetterberücksichtigung aus 5.1.1.4 stellt dann ein abschließender Vergleich in Abb. 5.3 der Basisausprägung aus 4.4 gegenüber.

Der Vergleich der beiden Konvergenzermethoden aus 5.1.1.2 zeigt nur tendenzielle nicht signifikante Unterschiede. Daher zeigt Abb. 5.2 nicht, wie für andere Teilmodelluntersuchungen, nur den MEDPE (oben), sondern auch den MEDAPE (unten). Die über die Anregung ermittelte Konvergenz (1) führt im MEDPE zwar zu etwas weniger Streuung im IQR, welche sich aber nur in Richtung zu niedriger Mittenfehler verschiebt. Darüber hinaus spricht der Erwartungswert tendenziell, aber nicht signifikant, für die Konvergenzermethoden mit einer Schwelle der Parametervarianz (2). Diese ist speziell im MEDAPE auch besser. Dies zeigt sich zwar nur mit etwas weniger Streuung im IQR, aber umso mehr im deutlich besseren Median, wenn auch nicht signifikant. Die Unterschiede sind zwar nicht signifikant, aber im MEDAPE tendenziell erkennbar.

Da die Einstellung der beiden Methoden zur Konvergenzermethoden an den gleichen Daten nach gleichen Maßgaben erfolgte, sind die sich zeigenden nur kleinen Unterschiede nachvollziehbar. Dennoch ist der Ansatz über die Parametervarianz hier robuster. Das zeigt sich jedoch nur im MEDAPE, was an Mittelungen positiver und negativer Fehler im relativen Fehlermaß liegen kann. Das bessere Abschneiden des Parametervarianz-Ansatzes ist aber hier zu erwarten, da der Luftwiderstandsparameter über die Fahrt recht konstant ist. Insgesamt sollte die Fahrwiderstandsschätzung innerhalb des Antriebsmodel-

les die Konvergenzerkennung mittels einer zu unterschreitenden Parametervarianzschwelle vorziehen. Dies zeigt sich insbesondere auch im später gezeigten Zusammenspiel mit der Windberücksichtigung im Schätzerinput.

Konvergenzerkennung:



Konvergenzerkennung:




Abb. 5.2: Bewertung zweier Konvergenzerkennungen der Fahrwiderstandsschätzung bewertet ab Konvergenzzeitpunkt mit (unten) MEDPE (oben) MEDAPE

Die Verwendung eines Schätzers sowie die Berücksichtigung der Wettereinflüsse im Fahrwiderstandsmodell ermöglicht jeweils eine signifikante Verbesserung. Dies zeigen in Abb. 5.3 die schätzerbasierten Ergebnisse für eine Bewertung ab dem Fahrtstart (a) und eine Prognose erst ab erkannter Konvergenz (b). Ersteres enthält damit neben der Prognose mit Parametern aus konvergierter Schätzung auch eine Initialphase, die sich mangels geschätzter Werte auf die Basisausprägung stützt, wobei bei (3) immer Wetteranpassungen erfolgen.

Entsprechend Abb. 5.3 hat das Fahrwiderstandsmodell mit dem Schätzer (2) aus 5.1.1.1, auf die ganze Fahrt (a) gerechnet im Median einen halb so großen Fehler und der sich mit dem Wettermodell (3a) aus 5.1.1.4 halbiert. Diese Verbesserung ist ab der Konvergenz für jeweils (b) nochmals erkennbar besser, wenn auch nicht signifikant. Dabei reduziert der eigenständige Schätzer zwar die Streuung, aber mit dem Wettermodell steigt diese wieder etwas. Die beschriebenen Tendenzen zeigen sich in ähnlicher Form über alle am Ende von 4.4.4 eingeführten Validierungsgruppen, was Abb. 5.4 zeigt.




Abb. 5.3: Bewertung der Fahrwiderstandsmodelle

Die gestiegene Streuung des Wettermodells könnte daran liegen, dass bei manchen Fahrten die Wetteranpassungen nicht so gut zutreffen, da etwa der Wind durch Vegetation oder Bebauung abgeschwächt ist. Abb. 5.4 deutet darauf hin, dass gerade bei Stadtfahrten der Energiebedarf etwa wegen Bebauung schlechter und mitunter zu niedrig prognostiziert wird. Zudem finden hier, anders als bei Überlandfahrten, viele kürzere und teils stärkere Verzögerungen statt, welche über die Streckenabschnitte gemittelt erfasst werden. Daher ist davon auszugehen, dass das Modell die rekuperierbare Energie überschätzt und mehr mechanisch gebremst wird. Dies geschieht, obwohl das Modell die Systemgrenzen der Rekuperation berücksichtigt. Dagegen sind die Ergebnisse jedoch gerade auf Autobahnfahrten besonders gut, was sich mit weniger Beschleunigungen und Vegetation bzw. Bebauung erklären lässt, welche die Windmodellierung stören. Zudem ist gerade hier der Einfluss entsprechend der Sensitivitätsanalyse in 3 am größten.

5.1.1.6 Fazit

Insgesamt ist ein Fahrwiderstandsmodell mit Schätzer und Modellierung von Wettereinflüssen für die Vollaussprägung in Form eines möglichst genauen Energiebedarfsprognosemodells zu bevorzugen. Dies ist zwar mit größerem Aufwand für die Fahrwiderstandsschätzung sowie Wetterprognose und -anpassungen verbunden, resultiert aber in signifikant besseren Ergebnissen. Dafür finden die in der Sensitivitätsanalyse in 3 ermittelten Einflüsse explizit oder nach

der Schätzung zumindest implizit Berücksichtigung. Damit berücksichtigt die Vollaussprägung der Energiebedarfsprognose die identifizierten relevanten Einflüsse auf die Fahrwiderstände umfänglich.

Fahrwiderstandsm.: Gruppe:

(1) Datenblatt	Stadt	(a) Start; n=7
	Land	n=27
	Autobahn	n=95
	Typisch	n=5
	Gesamt	n=233
(2) Schätzer	Stadt	n=7
		(b) gelernt; n=7
	Land	(a) Start; n=27
		(b) gelernt; n=27
	Autobahn	(a) Start; n=95
		(b) gelernt; n=95
	Typisch	(a) Start; n=5
		(b) gelernt; n=5
	Gesamt	(a) Start; n=233
		(b) gelernt; n=233
(3) Schätzer & Wettermodell	Stadt	(a) Start; n=7
		(b) gelernt; n=7
	Land	(a) Start; n=27
		(b) gelernt; n=27
	Autobahn	(a) Start; n=95
		(b) gelernt; n=95
	Typisch	(a) Start; n=5
		(b) gelernt; n=5
	Gesamt	(a) Start; n=233
		(b) gelernt; n=233

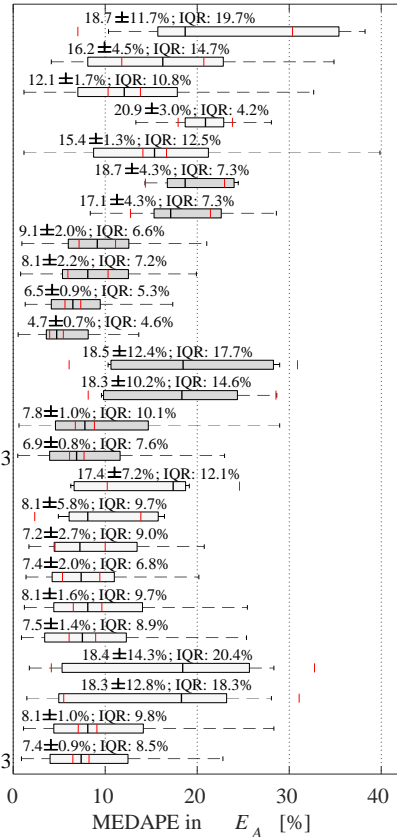


Abb. 5.4: Bewertung der Fahrwiderstandsmodelle für verschiedene Validierungsgruppen für (2) und (3) ab Schätzerkonvergenz

5.1.2 Effizienz

Das bisher beschriebene Fahrwiderstandsmodell berechnet aus den FPKA den Radenergiebedarf. Darauf fußend benötigt die Berechnung des Antriebsenergiebedarfs ein Modell der Fahrzeugeffizienzen. Dieses muss die in 2.1.2 beschriebene Komponentenverluste erfassen. Dazu erläutert und bewertet dieses Kapitel zwei Ansätze und wählt einen für die Vollausprägung der Energiebedarfsprognose aus.

5.1.2.1 Kennfeldmodell

Der erste Modellansatz stützt sich auf die Kennfelder der Getriebe-, Motor- und Invertereffizienzen. Diese Kennfelder verwendet auch das detaillierte Validierungsmodell in 3.2.1. Hier nutzt das Antriebseffizienzmodell zusätzlich die Eigenschaft der FPKA, die Effizienzrechnung entsprechend (4.6) der Richtung der Energieflüsse am Rad anzusetzen. Die Effizienzen und somit die Kennfelder hängen von Geschwindigkeit und Radmoment ab. Neben der aus den FPKA bekannten MG ist also ein Radmoment für die Rekuperation bzw. den Vortrieb abzuschätzen. Dies lässt sich aus der Radleistung P_{RD} mit der Raddrehgeschwindigkeit ω_{RD} bestimmen, die über den Radradius r_{RD} von der bereits bekannten Geschwindigkeit MG abhängt. Die Ermittlung von P_{RD} kann aus (4.6) die Radenergien nutzen, muss dazu aber eine Annahme treffen, wie lange die jeweiligen Leistungen anliegen. Die Gesamtzeit ist aus Streckenabschnittslänge und MG bekannt. Die zeitliche Aufteilung lässt sich jedoch nur abhängig von den absoluten Anteilen der rekuperierten und der für Vortrieb benötigten Energien schätzen. Die alternative Annahme, die Leistung für die gesamte Zeit auf dem Streckenabschnitt zu berechnen, würde zu einer stärkeren Abweichung in Richtung zu geringen Leistungsbetriebspunkten führen. Mit diesen separaten Zeiten und den Radleistungen für die Vortriebs- und Rekuperationsphasen können die beschriebenen Kennfelder die zugehörigen Verlustleistungen bereitstellen. Somit kann das Kennfeldmodell die Energieverluste der Wandlung von elektrischer in mechanischer Energie im Antriebsstrang in beiden Richtungen beschreiben.

5.1.2.2 Schätzermodell

Eben die oben ermittelten Radmoment- und Drehzahlbetriebspunkte können auch Prognoseinput für ein angelerntes Effizienzmodell sein. Ähnlich wie für die Fahrwiderstandseigenschaften (2.3) bis (2.6) und (2.8), beschreiben (2.11) bis (2.14) die physikalischen Effizienzeigenschaften des Antriebsstranges. Mit dem Anlernen eines Modells, basierend auf diesem Ansatz, beschäftigt sich [129, betreute Abschlussarbeit]. Das hier gezeigte Schätzermodell nutzt die dort prinzipiell auf [35] basierend aufgebaute Signalverarbeitung und Schätzeralgorithmen mit dem im Folgenden erklärten Antriebsmodell.

Antriebsstrangmodell

Das Fahrwiderstandsmodell stellt in der Prognose dem Effizienzmodell Radmoment und -drehzahl zur Verfügung. Davon abhängig muss dieses die physikalischen Effizienzabhängigkeiten modellieren. Im Folgenden wird das Schätzermodell erläutert, wie in [129, betreute Abschlussarbeit, S. 43] prinzipiell beschrieben, aber statt dem Fokus dort auf eine zeitkontinuierliche Prognose braucht das Modell aus 4.2 eine straßenabschnittsweise Prognose, was im Folgenden beschriebene Modellunterschiede nötig macht. Zum Anlernen benötigt das des Schätzermodells die Eingangswerte, möglichst direkt aus den verfügbaren Fahrzeugbusgrößen. Das Radmoment lässt sich wie in (5.1) für die Fahrwiderstandsschätzung aus dem Motormoment T_M ableiten. Das Motormoment enthalten die in 4.4.4 beschriebenen Datenaufzeichnungen genauso wie die noch benötigten Raddrehzahlen ω_M . Damit kann ein Schätzermodell, basierend auf den gleichen Inputgrößen wie das Kennfeldmodell, die Antriebsstrangeffizienz zur Berechnung der Verlustleistung P_{Vl} mit anlernen. [129, betreute Abschlussarbeit]

Dieses Modell muss die relevanten Verlustmechanismen des Antriebsstranges berücksichtigen. Die folgenden Absätze erläutern, wie das dem Schätzer zu Grunde liegende Modell die Leerlauf-, Leitungs-, Motor-, Inverter-, und Getriebeeigenschaften erfasst.

Zunächst benötigt ein permanenterregter Synchronmotor, wie der des BMW i3, im Leerlauf Strom, der das Moment durch die Selbstinduktion der Permanentmagnete kompensiert, was im Leerlauf alleinig wirkt, aber auch

wenn der Motor Moment erzeugt, kompensiert werden muss. Das bedeutet, dass das Effizienzmodell (5.4), falls keine mechanische Motorleistung erbracht wird, auch eine Verlustleistung ausweisen muss. Dies beschreibt das Modell, mit dem Achsabschnittswert X_0 als Koeffizient der Verluste bei Nullmomentregelung.

Darüber hinaus verursacht der elektrische Strom in Motor, Leitungen und Inverter entsprechend (2.11) Ohm'sche Verluste. Wie in 2.1.2 unter Inverter erläutert, ist der fließende Strom für den permanenterrregten Synchronemotor über Komponentenparameter proportional zum Motormoment und zur Flussdichte. Damit kann das Effizienzmodell (5.4) für die fließenden Ströme in (2.11) das Motormoment T_M als Repräsentant nutzen, das ohnehin auf einer Schätzung basiert, die eine steuervergängerinterne Strommessung als Grundlage nutzt [129, betreute Abschlussarbeit, S. 43]. Dieses Moment steht dem anzulernenden Systemparameter X_Ω gegenüber, welcher den resultierenden Leitungswiderstand sowie die Proportionalitätskonstante zwischen Motormoment und -strom darstellt. [129, betreute Abschlussarbeit, S. 43]

Um den fließenden Strom zu regeln, schaltet der Inverter diesen, was stromabhängige Verluste zur Folge hat, entsprechend (2.14). Da eine Verlustleistung definitionsgemäß positiv ist, fließt diese in (5.4) als Absolutwert des Motormoments ein. Das Moment repräsentiert wiederum den Strom. Der damit anlernbare Koeffizient X_S der Inverterschaltverluste aggregiert damit die Inverterparameter aus (2.14), sowie das Verhältnis zwischen Motorstrom und -moment.

$$\min \left(P_{VI} - \begin{bmatrix} 1 \\ T_M^2 \\ \text{abs}(T_M) \\ T_M^2 \cdot \omega_M \end{bmatrix}^T \begin{bmatrix} X_0 \\ X_\Omega \\ X_S \\ X_H \end{bmatrix} \right) \quad (5.4)$$

$$P_{VI} = P_A - P_{RD} = P_A - T_M \cdot \eta_A(T_M, \omega_M)^{\text{sgn}(T_M)} \cdot i_{M,RD} \cdot \omega_M \quad (5.5)$$

Mit dem Ziel der Momenterzeugung regelt das Inverterschalten über den Strom im Elektromotor den Magnetfeldfluss. Daraus resultiert ein rotierendes Magnetfeld, welches auf zwei Wegen weitere Verluste verursacht. Zum einen

verläuft der Auf- und Abbau des Magnetfeldes immer unterproportional zum Verlauf des verursachenden Stromes, was Hystereseverluste mit sich bringt. Zum anderen induziert es in alle elektrisch leitenden Materialien verlustbehaftete Wirbelströme. Voruntersuchungen in [129, betreute Abschlussarbeit, S. 43] zeigen, dass eine Berücksichtigung der Wirbelströme im Schätzermodell keine signifikante Verbesserung des Modelles bewirkt. Das lässt sich damit erklären, dass alle starkem magnetischen Fluss ausgesetzten Bauteile aus gestapelten, sehr dünnen Blechen bestehen, welche die Verluste durch den quadratischen Einfluss der Dicke, nach (2.13), sehr stark reduzieren. Anders als in Asynchronmotoren mit Stromfluss im Rotor ist der Einfluss der Wirbelströme also vernachlässigbar. Das gilt insbesondere unter dem zusätzlichen Blickwinkel, dass weniger Modellbestandteile dem Schätzer weniger Freiheitsgrade lassen und damit mehr Stabilität geben.

Dagegen sind die Hystereseverluste begrenzt über konstruktive Maßnahmen reduzierbar und nur von den Materialeigenschaften der ferromagnetischen Motorteile abhängig. Nach (2.12) steigen diese Verluste mit der Frequenz der Umpolung als auch näherungsweise quadratisch mit der magnetischen Flussdichte. Die Umpolungsfrequenz hängt über die Polpaarzahl, für einen Synchronmotor wie im BMW i3, direkt von der Motordrehzahl ω_M ab. Das kann der Modellkoeffizient für Hystereseverluste X_H im Schätzermodell anlernen. Dem steht zusätzlich der Einfluss der magnetischen Flussdichte gegenüber, die jedoch wie oben erläutert auch durch das Motormoment repräsentiert werden kann. Dementsprechend ist das Effizienzmodell (5.4) in der Lage die relevantesten Effizienzmechanismen des elektrischen Antriebsstranges bis zur Batterieklammer zu erfassen.

Das in (5.4) beschriebene Modell unterscheidet sich, bis auf die Modellierung der Ohm'schen Verluste, von dem aus [129, betreute Abschlussarbeit, S. 43]. Dort liegt der Modellierungsfokus auf einer zeitkontinuierlichen Prognose der Verlustleistung, anders als für die hier benötigte straßenabschnittsweise Prognose. Für die zeitkontinuierliche Anwendung erzielt [129] vielversprechende Ergebnisse, aber für die Verwendung hier ist insbesondere der zusätzliche Parameter für die Nullmomentregelung notwendig. Ist die zeitliche Diskretisierung feiner gewählt, zeigen tiefergehende Analysen, dass sich der Unterschied

verkleinert. Das lässt sich dadurch erklären, dass die Mittelung der Momente entlang der Segmente zu tendenziell geringeren Werten führt, die näher an eben dem Nullmomentregelungsfall liegen. Sind diese also nicht berücksichtigt, kommt es hier zu systematischen Fehlern im Ergebnis.

Die Schätzung und Signalverarbeitung stützen sich auf [129, betreute Abschlussarbeit, S. 43]. Dabei erfolgt die Verarbeitung der Signale analog der für die Fahrwiderstandsschätzung, wie in 5.1.1.1 erläutert. Dementsprechend übernimmt ein PKS die Signalglättung. Zudem findet die eigentliche Modellschätzung nur statt, wenn das Fahrzeug sich nicht nahe Stillstand, mechanisch ungebremst durch die Radbremsen oder mit vorgespanntem Antriebsstrang bewegt [129, betreute Abschlussarbeit, S. 43]. Dies stellt eine fehlerbereinigte Schätzung ausschließlich im Fahrzustand sicher.

Das so geschätzte Effizienzmodell beinhaltet zwei Annahmen bezüglich der Komponententemperaturen und Getriebeeffizienz. Zunächst zeigen Voruntersuchungen in [129, betreute Abschlussarbeit, S. 54-57] und eigene, tiefer gehende Voranalysen, dass die Verwendung von bei der letzten Fahrt geschätzten Parametern für die Prognose einer nachfolgenden Fahrt ausreichend gute Ergebnisse liefert. Der Unterschied zwischen der Schätzung von aktueller und letzter Fahrt liegt im MEDAPE des Antriebsenergieverbrauchs im Median bei 0,3 %-Punkten. Dieses Ergebnis schließt verschiedene Umgebungstemperaturen ein. Das ist damit zu erklären, dass eine Kühlung die Antriebsstrangkomponenten in einem eingeschränkten Temperaturband hält. Damit sind hier Temperatureinflüsse vernachlässigbar. Dagegen ist der Einfluss der Getriebeeffizienz zwar nicht vernachlässigbar, aber wie in 2.1.2 unter Getriebe erläutert, von nachrangiger Größenordnung. Damit ist eine implizite Berücksichtigung nach (5.4) ausreichend. Es besteht aber auch die Möglichkeit, die über Lebensdauer veränderlichen Effizienzen über eine Motormomentkompensation in die Schätzung in (5.5) einfließen zu lassen. Dazu ist jeweils in der Ebene ein Ausrollvorgang mit null Motormoment einer danach folgenden mäßigen Beschleunigung, um Radschlupf gering zu halten, gegenüberzustellen. Diese Gegenüberstellung muss bei geringer Geschwindigkeit und erfolgen. Das Verlustmoment im Getriebe ergibt sich dann als Differenz aus dem Motormoment bei Beschleunigung und über den Radradius aus der mit der Ausrollkurve

ermittelbaren Ausrollwiderstandskraft, entsprechend [132, S. 12]. Damit ist die Getriebeeffizienz, welche sich durch Abnutzung über die Nutzungszeitdauer verändern kann, im Modell kalibrierbar. Für eine weitere Anwendung und Validierung dieser Kompensation wären jedoch Daten über eine für die Abnutzung relevante Nutzungszeitdauer notwendig. Dazu wäre die Sammlung der Felddaten aus 4.4.4 am besten über den gesamten Fahrzeuglebenszyklus notwendig, was hier nicht realisierbar war. Ohnedies kann das Effizienzmodell dennoch die relevantesten Effizienzen im Antriebsstrang modellieren und mit folgender Algorithmik anlernen.

Algorithmen

Wie für den Fahrwiderstandsschätzer vergleicht [129, betreute Abschlussarbeit, S. 58-60] auch die in Abb. 5.1 gezeigten Algorithmen für die Effizienzschätzung. In [129] zeigt sich nur ein deutlicher Unterschied zwischen den Algorithmen. Wie in Abb. 5.1 ist ein einfacher RLS deutlich schlechter als andere Algorithmen. Tendenziell am besten, daher auch hier verwendet, ist jedoch ein SGIVMKF Kalmanfilter im Schätzen der Effizienzparameter [129].

Konvergenzerkennung

Ähnlich wie die Fahrwiderstandsschätzung in 5.1.1.2 verwendet auch die Effizienzschätzung angepasste Logiken, wie die beiden dort beschriebenen. Das erste, sich auf die Varianz der Parameter stützende Konvergenzentscheidungskriterium, verwendet hier die Varianz des Parameters der Hystereseverluste X_H . Entsprechend [129, S. 46–50] ist die Schätzung unter einer Varianz von $2 \cdot 10^{-10}$ als konvergiert anzunehmen. Dies gilt analog für die Konvergenzerkennung über die Anregung mit dem zeitlichen diskreten Raddrehwinkelintegral $\sum \omega_R \cdot \Delta t$, welches wiederum mit der bis dahin gefahrene Zeit $\sum \Delta t$ normiert ist, ab einem Wert von $1,5 \cdot 10^6 \frac{s}{s}$. Diese beiden Konvergenzerkennungsmethoden stellt 5.1.2.3 bezüglich ihrer Genauigkeit gegenüber. Darauf basierend kann die Vollaussprägung den genaueren Ansatz für die folgende Auswahl des Effizienzmodells verwenden.

Initialannahmen

Bevor die geschätzten Effizienzparameter nach erkannter Konvergenz in der Prognose verfügbar sind, ist eine Initialannahme notwendig. Wie bereits für die Komponententemperatureinflüsse erwähnt, ist eine Prognose mit Parametern der letzten Fahrt bereits recht gut. Daher verwendet die Energiebedarfsprognose initial die Effizienzparameter vom Ende der letzten Fahrt.

5.1.2.3 Ergebnis

Dieser Abschnitt erörtert die mit den beiden oben erläuterten Effizienzmodellen erreichbare Genauigkeit in der Berechnung der Antriebsenergie E_A entsprechend 4.4.2. Dazu erfolgt erst eine Auswahl der Konvergenzerkennung für das Schätzermodell. Dabei basieren alle Analysen im Sinne einer Einzelmodellvariation auf den Fahrwiderstandswerten der Basisausprägung aus 4.4, die entsprechend 5.1.1.5 eher zur Unterschätzung des Antriebsenergiebedarfs führen.

Konvergenzerkennung:




Abb. 5.5: Bewertung zweier Konvergenzerkennungen der Effizienzschätzung

Für die Analyse der Konvergenzerkennungen deutet Abb. 5.5 darauf hin, dass die Konvergenzerkennung über die Anregung genauer ist. Dazu zeigt sie die energetische Abweichung für eine Prognose ab konvergierter Schätzung. Der Unterschied ist zwar nicht signifikant, jedoch ist die Streuung von (1) im IQR geringer und der Median für (1) näher am Soll als für (2). Daher favorisiert die Effizienzschätzung die anregungsbasierte Konvergenzerkennung.

Hier ist, anders als für die Fahrwiderstandsschätzung, die anregungsbasierte Konvergenzerkennung geeigneter. Das deutet darauf hin, dass tendenziell mehr im Modell nicht erfasste Varianz vorhanden ist. Das kann an zwei Dingen liegen. Entweder kann das Modell der Hystereseverluste ungenau sein oder das

Modell kann einen Einfluss nicht abbilden. Das Hysteresemodell (2.12) enthält eine exponentielle Abhängigkeit, deren Exponent abhängig von verschiedenen Faktoren schwankt. Dies kann bezüglich der Konvergenzerkennung zu schlechter nutzbaren Parametervarianzverläufen führen. Zudem können die in 5.1.2.2 erläuterten Vereinfachungen zur Fokussierung auf Kerneffekte zu ungünstigen Anlernverläufen führen. Wegen dieser Unschärfen im Effizienzmodell, welche sich in den Modellinputs nicht auswirken, ist die anregungsbaasierte Konvergenzerkennung zu bevorzugen.




Abb. 5.6: Bewertung verschiedener Effizienzmodelle

Basierend auf der ausgewählten Konvergenzerkennung vergleicht Abb. 5.6 das kennfeld- (1) mit dem schätzerbasierten (2) Effizienzmodell. Dabei zeigt die Auswertung neben der Prognose der ganzen Fahrt (a) für den Schätzer auch das Ergebnis ab Konvergenz (b). Es zeigt sich, dass das Kennfeldmodell (1) im Erwartungswert auf die ganze Fahrt signifikant besser ist als das angelernte Schätzermodell (2a). Dieser Unterschied ist jedoch nach Konvergenz (2b) etwas geringer und nicht signifikant. Dagegen zeigt sich aber, dass das Anlernen zu weniger Streuung im IQR führt. Der Kennfeldansatz (1) streut jedoch vornehmlich in Richtung eines geringeren Fehlers im Erwartungswert. Damit ist diese Streuung als weniger wichtig zu betrachten.

5.1.2.4 Fazit

Insgesamt ist das Kennfeldmodell für die Vollausrprägung besser. Dies zeigt sich gerade im Zusammenhang mit den Ergebnissen des Fahrwiderstandsmodelles. Dieses Kennfeldmodell erfasst viele Einflüsse, die zu einer zu geringen Prognose führen, aber bleibt dennoch tendenziell unter null, wie Abb. 5.3 zeigt.

Hier wäre das zu noch niedrigeren Ergebnissen führende Effizienzschätzermodell kontraproduktiv, wie später Abb. 5.6 (oben) zeigt. Ein kennfeldbasiertes Effizienzmodell benötigt zwar keine kontinuierliche Schätzung, jedoch mehr Speicherplatz als die vier Parameter des Schätzermodells. Das Schätzermodell ist allerdings flexibel für verschiedene Fahrzeuge mit ähnlichem Antrieb verwendbar. Dagegen ist das so angelehrnte Modell nur in der Lage die Kerneffekte abzubilden und kann nicht wie ein Kennfeld auch kleinere Effekte erfassen. Diese können in Summe auch relevant sein. Insgesamt ist das Kennfeldeffizienzmodell das für die Vollaussprägung favorisierte, weil es im Relativfehler deutlich näher am Soll ist als das Schätzermodell.

5.1.3 Ergebnis

Entsprechend den bisher ausgewählten Teilmodellen des Antriebsenergiebedarfsmodells folgt der Vergleich dieser zu einem Regressions- sowie zwei Literaturmodellen. Die Ergebnisse dieser Gegenüberstellung in der Antriebsenergie zeigt Abb. 5.7. Dabei entspricht Modell (1) der Antriebsmodellkonfiguration der Vollaussprägung. Dagegen ist (2) das vollständig physikalische Modell mit neben angelehrnten Fahrwiderständen auch angelehrnten Antriebs efficienzen. Für beide Modelle zeigt Abb. 5.7 das Ergebnis für eine Prognose ab Fahrtstart (a) und nur ab Konvergenz (b). Dabei verwendet (a) die Initialisierungswerte bis zur Konvergenz und danach das gelernte Modell. Wie (1) und (2) stützt sich (3) auf die FPKA des in 4.3 hergeleiteten übergeordneten Ansatzes. Dabei lernt eine lineare Regression die Fahrwiderstände und Antriebs effizienz basierend auf der gesamten vorherigen Fahrt. Die Literaturmodelle aus 2.2 repräsentieren das Modell von Boriboonsomsin (4) [80] und Qi (5) [1]. Beide Modelle haben eigene energetische Fahrprofilparameter und Lernansätze, wobei für Details auf 2.2.1 verwiesen sei. Diese Ergebnisse decken somit die verschiedenen Modellierungstypen für den Antriebsstrang ab und erlauben eine fundierte Auswahl der Antriebsmodellausprägungen.

Zunächst zeigt sich dabei im MEDPE in Abb. 5.7 (oben), dass nur (1b), (3) und (5) im Erwartungswert keinen signifikanten systematischen Fehler aufweisen. Jedoch ist die Streuung im IQR von (1b) gerade gegenüber (5) tendenziell geringer. Zwar streut Modell (2) noch weniger, jedoch ist es signifikant zu

niedrig. Dagegen haben die beiden Literaturmodelle (4) und (5) zwar weniger Fehler im Erwartungswert, jedoch streuen beide tendenziell mehr als alle anderen Modelle. Nur die im MEDPE besten Modelle (1) und (3) haben mit dem nicht signifikant fehlerhaften Erwartungswert von $-1,4\%$ bzw. $-1,0\%$ eine teils halb so große Streuung im IQR als die Vergleichsmodelle. Jedoch ist (1) mit wetterangepasstem, lernendem Fahrwiderstandsmodell vorbehaltlich der Bewertung mit absoluten Fehlern, wegen der besseren physikalischen Nachvollziehbarkeit, die bevorzugte Konfiguration für die Vollaussprägung der Energiebedarfsprognose.

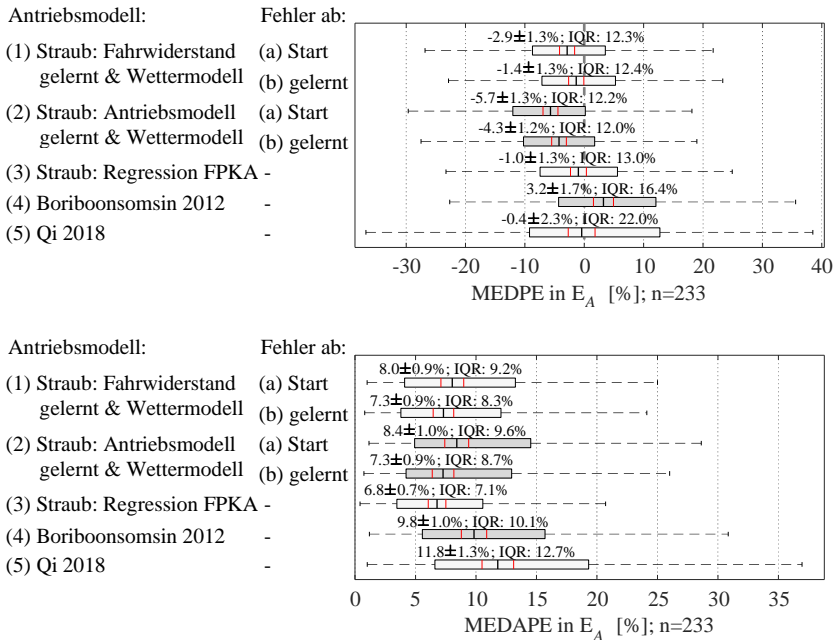


Abb. 5.7: Antriebsmodellbewertung basierend auf Soll-Fahrprofil mit MEDPE (oben) und MEDAPE (unten)

Der relativen Fehler zeigt, dass alle auf den FPKA basierenden Modelle zumindest tendenziell zu optimistisch sind. Hier überlagern sich zwei Modelle-

enschaften. Wie 4.2 erläutert, berücksichtigt das Modell des Antriebs auf der einen Seite die Leistungsgrenzen des Fahrzeuges insbesondere bezüglich des Verzögerungsvermögens durch Rekuperation. Folglich rechnet das Antriebsmodell nur bis zu einer Grenze mit Rekuperation, welche vom Fahrzeug abhängt. Darüber nimmt es mechanisches Bremsen an. Auf der anderen Seite ist der zugehörige Fahrprofil-Input des Antriebsmodelles, die IBR, über die Streckenabschnitte gemittelt. Diese Mittelung führt dazu, dass der IBR eines Abschnitts mit mechanischer Bremsung unter der Rekuperationsgrenze liegen kann und daher das Antriebsmodell diesen nicht limitiert. Die daraus folgende Überrepräsentation von Energierückgewinnung macht die auf FPKA basierenden Modelle optimistischer, wobei gerade das Regressionsmodell (3) diesen Effekt am besten berücksichtigten kann, wie Abb. 5.7 (oben) zeigt.

Abb. 5.7 (unten) zeigt die gleichen Modelle, jedoch analysiert mit dem MEDAPE. Diese absolute Betrachtung weist nur signifikante Unterschiede zwischen der Modellgruppe (1) bis (3) und Literaturmodellgruppe (4) und (5) auf. Hier zeigt sich die Eigenschaft des MEDAPE, dass die größere Streuung der Literaturmodelle nicht nur zu Streuung im MEDAPE führt, sondern auch zu höheren MEDAPE Werten. Für die beiden sich während der Fahrt anpassen den Modelle (1) und (2), verbessert sich der MEDAPE in Median und Streuung nach dem Anlernen in (b) tendenziell, wenn auch nicht signifikant. Die physikalischen Modelle (1) und (2) zeigen sich im MEDAPE-Median gleich gut, anders als im MEDPE. Ebenfalls anders als in der relativen Bewertung, ist die Regression mit FPKA (3) nicht nur im Median mit 6,8 %, sondern auch mit einem Interquartilsabstand von 7,1 % tendenziell am besten, wenn auch nicht signifikant.

5.1.4 Fazit

Auf Antriebsebene ist von den physikalischen Modellen, das mit angelernten Fahrwiderständen, Wetterberücksichtigung und einem Effizienzkennfeld (1) am besten für die Vollaussprägung geeignet. Dies deckt sich mit dem Fazit in 5.1.1.6 für das Fahrwiderstands- und 5.1.2.4 für das Effizienzmodell. Das FPKA-Regressionsmodell (3) ist in den Erwartungswerten zwar tendenziell besser. Zudem ist seine Streuung im absoluten Fehler zwar kleiner, aber in der

relativen Betrachtung größer. Das könnte darauf hindeuten, dass das Regressionsmodell (3) einseitiger je Fahrt ist und weniger gleichmäßig streut als das Modell (1). Dies kann daran liegen, dass das Regressionsmodell Wettereinflüsse nicht explizit berücksichtigt. Weil die Vollaussprägung alle Effekte der aktuellen Fahrt möglichst genau erfassen soll, nutzt diese das (1) mit angelearntem Fahrwiderstandsmodell und Anpassung entsprechend der Wetterprognose.

Dennoch ist die FPKA-Regression (3) in der Lage verschiedene Effekte zumindest grob zusammengefasst zu erfassen. Das zeigt sich in den fast so überzeugenden Ergebnissen wie für Modell (1) bei weniger Wetter- und Effizienzmodellierungsaufwand. Eben wegen dieses geringeren Aufwands und dem nicht kontinuierlichen, sondern nur einmaligen übergreifenden Anlernen je Fahrt, nutzt die Paretoausprägung im Folgenden die FPKA-Regression (3).

5.2 Nebenverbraucher

Dieser Abschnitt erläutert und bewertet das Nebenverbrauchsmodell der Energiebedarfsprognose. Dies besteht aus Teilen für Innenraumtemperierungs- und Niedervoltsystemverbrauch. Deren Bewertung ist zusammen mit dem Antriebsmodell die Basis der Definition von Fahrzeugmodellausprägungen.

5.2.1 Innenraumtemperierung

Innerhalb der Nebenverbrauchermodellierung folgt zunächst die Methodik des Innenraumtemperierungsmodelles mit der Untersuchung seiner Varianten. Dieses soll die genaueste Ausprägung identifizieren für den, nach der Sensitivitätsuntersuchung in 3, relevantesten Nebenverbraucher.

5.2.1.1 Methode

Dazu benötigt die Energiebedarfsprognose des Anteils zur Innenraumtemperierung deren Leistung P_T je Streckenabschnitt, entsprechend (2.18) und (4.2). Analog der in 3 analysierten Abhängigkeit von der Sonneneinstrahlung und insbesondere der Umgebungstemperatur, benötigt das Modell diese als Ein-

gangsgrößen. Ein einfaches Konzept kann sich direkt auf eine Messung mit Sensoren im Fahrzeug stützen. Dies ermöglicht aber nur eine Prognose, welche Umgebungsbedingungen zum Prognosezeitpunkt extrapoliert. Gerade beim Start im Gebäude oder bei großen Unterschieden entlang der Route, ist dieser Ansatz unzureichend. Um dies zu umgehen, bezieht eine zweite Modellvariante die Eingangsgrößen entsprechend [120, betreute Abschlussarbeit, S. 31–34] aus einer Wetterprognose, welche A.2 beschreibt. Diese beiden Varianten können die Temperierungsleistung P_T je Streckenabschnitt zusammen mit einem fahrzeugspezifisch vermessenen Kennfeld entsprechend Abb. 5.8 ermitteln. Diese Kennfelder ermöglichen die Prognose des Energiebedarfes basierend auf Werten von Sensoren oder einer Wetterprognose.

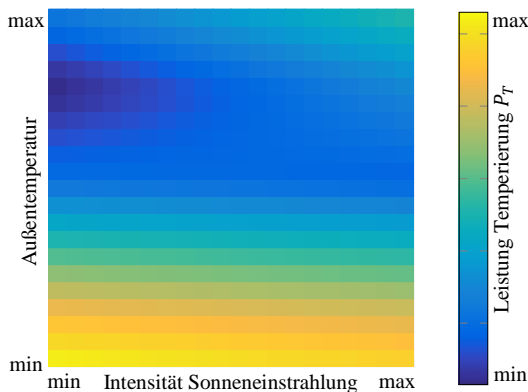



Abb. 5.8: Kennfeld der Temperierungsleistung nach [120, S. 26]

5.2.1.2 Ergebnis

Der Vergleich in Abb. 5.9 (oben) der beiden Varianten des Inputs für die Prognose des Innenraumtemperierungsenergiebedarfes zeigt, dass die Wetterprognose im Median ein 84,5 % genaueres Ergebnis ermöglicht. Dieser Unterschied ist statistisch signifikant. Dabei kommt es zwar zu mehr Streuung, was aber bei beiden Ansätzen Einstellungsänderungen deutlich beeinflussen. Ist etwa die Temperierung zu Fahrtbeginn abgeschaltet und wird während der Fahrt aktiviert, so kommt es zu einem Fehler von -100% . Das kann auch erklären, dass die Medianwerte beider Konzepte signifikant zu niedrige Ergeb-

nisse zeigen. Dennoch ist der Vorteil einer Verbrauchsprognose mit Wetterprognose so groß, dass er auch auf Gesamtenergieverbrauchsebene signifikant ist, wie Abb. 5.9 (unten) zeigt. Zudem deckt die Datenbasis aus 4.4.4 Wetterlagen über das gesamte Jahr ab, was die Ergebnisse zuverlässiger macht.

Input Temperierungsmodell:



Input Temperierungsmodell:




Abb. 5.9: Bewertung Innenraumtemperierungsverbrauchsprognose basierend auf Soll-Fahrprofil für verschiedene Inputs auf Temperierungs- (oben) und Gesamtverbrauchsebene (unten)

5.2.1.3 Fazit

Wegen der gezeigten Ergebnisse sollte die Vollaussprägung der Energiebedarfsprognose zur Vorhersage des Innenraumtemperierungsenergiebedarfes eine Wetterprognose als Eingangsgröße klar favorisieren. In der Literatur findet sich zwar ein entsprechendes Prognosemodell, das Wetterprognosen als Input verwendet, jedoch weist diese Offenlegung keine Genauigkeit oder weitere Modelleigenschaften aus [115]. Andere Modelle verwenden entweder die Temperatur des Sensors [67, S. 142–145; 100, S. 5934–5935; 133] oder direkt den Verbrauchsmittelwert [134; 135], geben aber keinen Genauigkeitseinfluss auf die Gesamtfahrzeugprognose an. Demgegenüber zeigen die Ergebnisse hier eine signifikante Verbesserung. Daher verwenden alle im Folgenden gezeigten Modelle den Ansatz basierend auf der Wetterprognose.

5.2.2 Niedervoltsystem

Anders als Schwankungen im Temperierungsenergiebedarf, sind die der Nebenverbraucher im Niedervoltbordnetz vernachlässigbar, wie 3.4 aufzeigt. Daher nutzt das Niedervoltverbrauchsmodell als Eingangsgröße nur die aktuelle Nebenverbraucherleistung P_{NV} für die Modellgleichungen (2.18) und (4.2).

Diese Extrapolation des aktuellen Verbrauches bewertet Abb. 5.10. Es zeigt sich, dass diese Annahme signifikant zu konservativ ist. Diese Überschätzung des Energiebedarfes lässt sich womöglich mit einem anfangs höherem Leiterwiderstand, welcher in Kupferleitungen beim Aufwärmen sinkt [136], oder höherer Rechenlast zum Fahrtstart z. B. für das Hochfahren der Systeme erklären. Nichtsdestotrotz bezieht sich diese Bewertung nur auf die 3,28 % des Gesamtenergiebedarfes, welche auf das Niedervoltbordnetz entfallen. Bezogen darauf ist der Median des MEDPE aus Abb. 5.10. nur noch 0,48 % groß. Dementsprechend ist die einfache Extrapolation des Ist-Zustandes eine legitime Annahme, wie sie auch andere verwenden [66, S. 58; 82, S. 9].




Abb. 5.10: Bewertung Niedervoltverbrauchsprognose basierend auf Soll-Fahrprofil

6 Fahrprofilprognose

Neben den bisher erläuterten Fahrzeugeinflüssen ist nach der Sensitivitätsuntersuchung aus 3 die Prognose des Fahrprofils mit Fahrer- und Verkehrseinfluss ein wichtiger Baustein der Energiebedarfsprognose. Dieser Abschnitt beschreibt die flottendatenbasierte Prognose der Fahrprofilinformation in Form der FPKA, die nach 4.3 aggregiert sind. Diese sind, zusammen mit den Fahrzeuggrößen aus Abschnitt 5, Kernbestandteil der Energiebedarfsprognose für eine Route. Die Erläuterung der Prognose der Fahrprofilinformation gliedert sich in diesem Kapitel in zwei Abschnitte entsprechend der in 4.2 skizzierten Schritte. Da sich die Prognose auf Fahrprofildaten einer Fahrzeugflotte stützt, erläutert 6.1 zunächst die Erfassung des Flottenverhaltens je Streckenabschnitt. Darauf basierend kann sich das Fahrermodell entsprechend 6.2 anlernen und fahrer- als auch verkehrsspezifisch das erwartete Fahrprofil vorhersagen.

6.1 Flottenverhalten

Dieses Kapitel leitet, nach der Beschreibung der zu Grunde liegenden Fahrprofildaten in 6.1.1, die darauf fußende Methodik zur Sammlung des Flottenverhaltens in 6.1.2 her. Dabei greift 6.1.3 einige Herausforderungen in der Umsetzung auf und zeigt Lösungsansätze sowie deren Wirksamkeit auf. Kurz gesagt, erfasst diese Methodik das Flottenverhalten der Fahrgesamtheit je Streckenabschnitt für die nachfolgende darauf basierende fahrerindividuelle Fahrprofilprognose.

6.1.1 Fahrprofildaten

Die Datenbasis der Erfassung des Flottenverhaltens sind geositionsbasierte Fahrprofildaten von BMW-Fahrzeugen. Dabei ist das Ziel, von den einzelnen Fahrzeugen möglichst wenig und anonymisierte, dennoch hochwertige

Information über Mobilfunk an den verarbeitenden Server zu senden. Zum einen benötigt die Erfassung des Fahrprofils eine Information zu Weg und Zeit. Zum anderen braucht die letztendliche Energiebedarfsprognose einer Route eine Zuordnung deren Streckenabschnitte zur digitalen Karte, was nur über die Geoposition möglich ist. Da sich der Weg zwischen den einzelnen Geopositionen auch für die Fahrprofilinformation verwenden lässt, müssen Fahrzeuge nur die Geopositionen und die zugehörigen Zeitstempel an den Server schicken. Dabei schneidet die Anonymisierung mittendrin zufällige Abschnitte und daneben insbesondere Start und Ziel der Fahrten aus. Das stellt sicher, dass nicht einzelne Fahrten über die Geopositionen einem Fahrer zugeordnet werden können und die Daten dennoch als Flotteninformation verwendbar bleiben. Die Geopositionen liegen dazu in den Fahrzeugen odometriefusioniert vor. Die folgende Konzeptbewertung nutzt solche Daten von Fahrzeugen mit entsprechender Hardwareausrüstung und nach Nutzerzustimmung. Der datenschutzkonform aufgezeichnete Rohdatensatz enthält aus Europa und Nordamerika 8,5 Terrabyte, aus der Zeit zwischen 01.09.2017 und 06.11.2017. Im Datensatz aus 4.4.4 finden sich 158,3 Gigabyte an Daten, die für Validierungsfahrten verwendbar sind. Deren Aufzeichnungen schließen $30,8 \cdot 10^6$ km an gefahrener Strecke mit $2,5 \cdot 10^{12}$ sekundenweisen Datenpunkten auf den Strecken der Fahrten aus 4.4.4 ein. Daher ist es für die Verarbeitung dieser Daten notwendig, auf Big-Data-Methoden zurückzugreifen, insbesondere bei Analyse der Gesamtdaten mit 8,5 Terrabyte. Die Verarbeitung findet dementsprechend verteilt auf mehreren Computern eines Rechenclusters statt und nutzt das dafür entworfene Programmierframework PySpark [137]. Dieses Framework ermöglicht es zu programmieren ohne größere Rücksicht auf die verteilt vorliegenden Daten und insbesondere deren Austausch zwischen den Computern zu nehmen. Damit ist es möglich, den großen Umfang an Fahrprofildaten für die im Folgenden beschriebene Flottenverhaltens Erfassung zugänglich zu machen.

6.1.2 Methodik

Die folgende Methodik der Flottenverhaltens Erfassung beschreibt die Schritte von Geolokalisationsmesspunkten zu kartenbezogenen Fahrprofilverteilungen für die Fahrprofilprognose. Dazu zeigt Abb. 6.1 den Überblick über die Fahr-

profilprognose, basierend auf Flottendaten für die Energiebedarfsprognose. In der Abbildung verdeutlichen zwei Boxen, welche Schritte im Fahrzeug (links) und auf einem Backend-Server (rechts) erfolgen. *Übernommener Abschnitt:* Im ersten Schritt A) zeichnet eine Fahrzeugflotte die Fahrdaten auf. [...] Die Fahrzeuge übertragen in B) diese Daten anonymisiert über das Mobilfunknetz an den Backend-Server. In Schritt C) findet im Backend ein Map-Matching statt, das zu jedem Datensatz eine Referenz zu dem zugehörigen Straßenabschnitt der Karte hinzufügt, die sogenannte Streckenabschnitt-ID. Das Map-Matching liefert auch die relative Position jedes Datensatzes entlang der Streckenabschnittslänge. Das genutzte Map-Matching basiert auf einem Hidden-Markov-Modell [128, S. 338]. Außerdem ermöglicht die Streckenabschnitt-ID, zusätzliche Kartenattribute aus der Karte zu jedem Datensatz hinzuzufügen. [*Dieser übernommene Abschnitt ist zur Einheitlichkeit dieser Arbeit neuformatiert und übersetzt. © CC BY 126 S. 4*] Dabei sind aus den in der digitalen Karte verfügbaren Attributen eines Streckenabschnitts insbesondere seine Länge, Straßenklasse, sein Geschwindigkeitslimit und das Steigungsprofil relevant. Damit stellt die digitale Karte entsprechend (4.1) bis (4.4) für die Energiebedarfsprognose relevante Informationen bereit, insbesondere zur Fahrprofilberechnung, wie es [125, S. 4; 126, S. 4] detailliert herleiten.

Übernommener Abschnitt: Genauer gesagt errechnet der Backend-Teil in Schritt D) des Systems unter Verwendung der hinzugefügten Streckenabschnittslängen, der relativen Position entlang eines Abschnitts und dem Zeitstempel das Fahrprofil. [...] Aus diesem Fahrprofil aggregiert der nachfolgende Schritt E) die energetischen FPKA für jeden überfahrenen Straßenabschnitt. [*Dieser übernommene Abschnitt ist zur Einheitlichkeit dieser Arbeit neuformatiert und übersetzt. © CC BY 126 S. 4*] Entlang dieser Streckenabschnitte repräsentieren die fünf aggregierten FPKA eine Stichprobe des energetischen Einflusses des Fahrprofils. Dabei erfolgt die Aggregation bezüglich der Diskretisierung mit der Länge der Streckenabschnitte entsprechend der Karte, da der Mehraufwand einer Unterteilung in feiner aufgelöste Teilabschnitte nicht signifikant genauer ist [125]. Eine Überprüfung gegenüber der laut [125] tendenziell genauesten Diskretisierung mit 50 m bestätigt dies für das Gesamtmodell in Abb. 6.8.




Abb. 6.1: Flottendatenbasierte Fahrprofilprognose der Energiebedarfsprognose [adaptiert aus 131, S. 138]

Schritt F) aggregiert mit (6.1) die sogenannten Fahrprofilkartenattributverteilungen (FPKAV) zur Erfassung jedes auftretenden Verhaltens in der Flotte. Dazu vereint Schritt F) die Stichproben Y_i aus n verschiedenen Fahrten in nichtparametrischen Verteilungen, in (6.1) nach [138, S. 653] beschrieben mit der Einheitsfunktion $I[Y_{j,i} \leq y]$, je Streckenabschnitt j und zeitlichen Halbstundenintervallen über den Tag [126, S. 4–5]. Dabei ist $Y_{j,i}$ eine Stichprobe der Zufallsvariablen Y und y ist ein beliebiger Wert im Wertebereich von Y .

$$\tilde{W}_j(y) = \tilde{P}_j[Y_j \leq y] = \frac{1}{n} \cdot \sum_{i=1}^n I[Y_{j,i} \leq y] \Big|_{\text{VFPKA}} \quad (6.1)$$

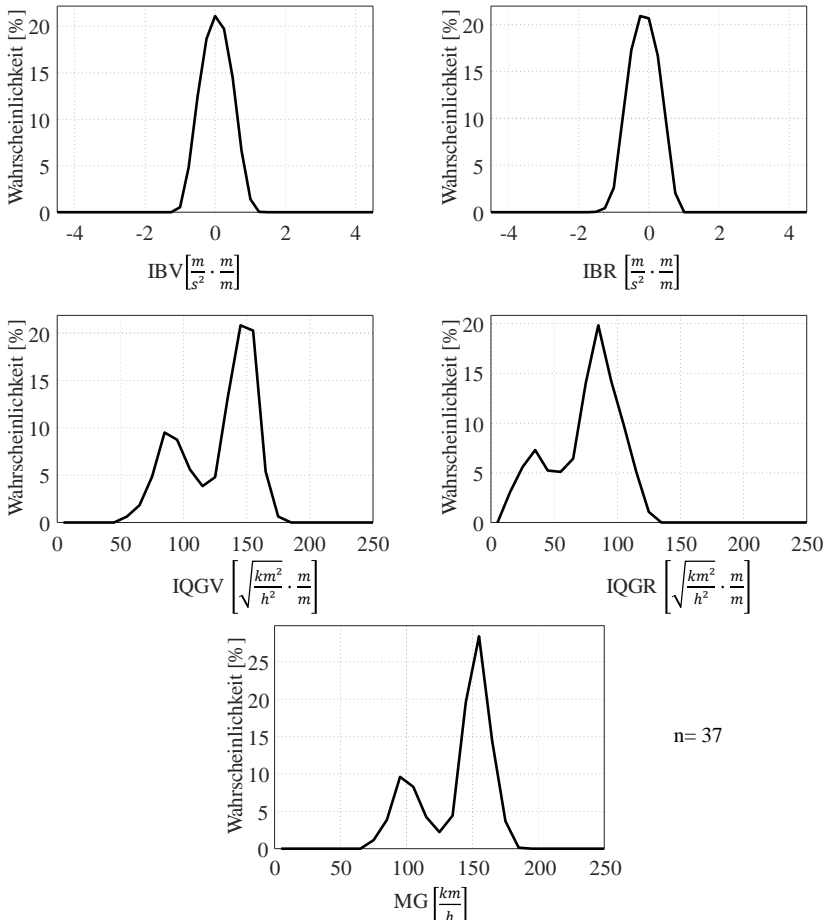


Abb. 6.2: Beispielhafte Energetische Fahrprofil-Kartenattributsverteilungen (FPKAV) auf einem Autobahnabschnitt

Für das Beispiel der MG ist dieser Wertebereich $Y_{MG} \in [0; \infty]$. Mit den MG-Stichproben $Y_{i, MG}$ aus der Flotte lässt sich eine diskrete Funktion der Wahrscheinlichkeit \tilde{W}_{MG} ermitteln. Dabei ist y eine beliebige MG und $\tilde{W}_{MG}(y)$ gibt an, wie wahrscheinlich innerhalb der Stichprobenwerte ein Wert kleiner oder gleich y ist. Dabei heißt diese Wahrscheinlichkeit Perzentil und y ist der

Perzentilwert innerhalb \tilde{W}_{MG} . Da immer wieder für Streckenabschnitte die Anzahl n an verfügbaren Stichprobenwerten sehr gering ist, wären die diskreten Abschnitte recht grob in den \tilde{W} . Daher glättet eine Kerndichteschätzung mit Epanechnikov-Kernel die Funktion und verwendet dazu die Kernelbreite aus [76, S. 35]. Über eine Auswertung dieser empirischen Wahrscheinlichkeitsfunktion $\tilde{W}(y)$ entlang eines definierten Gitters y_k (z. B. $y_1=10$ km/h, $y_2=20$ km/h, ..., $y_k=250$ km/h) erhält man die kumulativen Perzentilwerte $u_k = \tilde{W}(y_k)$. Diese Stützstellen sind die diskreten FPKAV. Entsprechend [138, S. 655] lassen sich die FPKAV als abschnittsweise lineare empirische Wahrscheinlichkeitsverteilung verwenden. Für alle fünf FPKAV zeigt Abb. 6.2 den beispielhaften Verlauf, jedoch für eine einfachere Interpretation in nicht kumulativer Darstellung. Für eine gegebene und segmentierte Route H) werden solche zeit- und segmentspezifischen FPKAV I) in G) dann an das Fahrzeug gesendet. Das mit den FPKAV erfasste Flottenverhalten ist die Basis für das in 6.2 erläuterte Fahrermodell K) und die Energiebedarfsprognose in I).

Das genutzte Flottenverhalten basiert auf verschiedensten Fahrzeugtypen und damit verschiedenen in 4.3 erläuterten Beschleunigungsgrenzen zwischen Vortrieb und Rekuperation. Da dies zu konzeptbedingten Fehlern führt, bewertet [125] eben diesen Übertrag von einer Flottengesamtheit auf extreme Fahrzeugeigenschaften. Diese Fehler zeigen sich insbesondere in der Aufteilung der Energieflussrichtungen. Dabei zeigt sich, dass der höchste Median im ME-DAPE höchstens 1.32 ± 0.234 % groß ist. Damit ist der Fehler deutlich kleiner als der in einer späteren Reichweitenprognose auch relevante Fehler der SOC-Schätzung von 4,8 % für einen SOC von 50% [62] und dementsprechend nicht zu groß. [125]

6.1.3 Herausforderungen bei der Umsetzung

Bei der Umsetzung des in Abb. 6.1 skizzierten Konzeptes der Fahrprofilprognose basierend auf Flottendaten für eine Energiebedarfsprognose gibt es verschiedene Herausforderungen. Wie bereits 6.1.1 erläutert ist es notwendig, für die zu verarbeitenden Datenumfänge auf verteilte Rechenansätze aus dem Big-Data-Umfeld zu setzen. Trotz der großen Menge an verfügbaren Daten in den

Testflottendaten, sind für die Prognose der in 4.4.4 beschriebenen Fahrten nur für 42,3 % der Straßenabschnitte exakt die richtigen Daten bzgl. Fahrtrichtung und Uhrzeit verfügbar. Dies zeigt Abb. 6.3 prinzipiell anhand zweier Beispielzeiträume. Jedoch liegen nur für 3,49 % der Straßenabschnitte keine Daten vor. Wie die prototypische Fahrprofilprognose damit umgehen kann erläutert 6.1.3.1. Darüber hinaus muss eine spätere Implementierung im Fahrzeug zwei weitere Aspekte berücksichtigen. Zum einen speichert das Fahrermodell das Fahrerverhalten, das aus Gründen des Datenschutzes idealerweise im Fahrzeug verbleiben sollte. Dies erschwert im Vergleich zu einer Speicherung auf einem Server ungewollte Zugriffe auf diese sensible Information. Um das Anlernen des Fahrerverhaltens zu ermöglichen ist es jedoch nötig, die gesamten FPKAV zumindest des überfahrenen Straßennetzes über alle Uhrzeiten ins Fahrzeug zu übermitteln oder dort zu speichern. Für die im Mittel ca. 9200 km, die ein deutscher Autofahrer im Jahr fährt [139], wären es gut zwei Gigabyte an zu übermittelnden Daten. Die dafür anfallenden Datenübertragungskosten machen eine Komprimierung unumgänglich. Die nur für die Umsetzung relevanten Herausforderungen des Datenschutzes und der Datenmengen behandelt Abschnitt 6.1.3.2.

6.1.3.1 Kartenabdeckung

Für die Energiebedarfsprognose einer Route enthalten die Flottendaten für manche Straßenabschnitte keine Information für die zeit- und richtungsspezifischen FPKAV. In Abb. 6.1 bedeutet das, dass Schritt F) für Schritt H) nicht alle FPKAV aller z Straßenabschnitte bereitstellen kann. Dies zeigt Abb. 6.3 für einen Ausschnitt nahe Karlsruhe durch Kennzeichnung der Straßen mit verfügbaren Daten in zwei Zeiträumen. Dazu beschreibt dieser Abschnitt im Folgenden zwei Ansätze aus [126] und [131] und analysiert, wie sich diese allein oder in Kombination am besten einsetzen lassen.

Der Datenergänzungsansatz in [131] basiert auf den verschiedenen Fällen an verfügbaren Informationen auf einem zu betrachtenden Streckenabschnitt.

___*Übernommener Abschnitt*: Die Fälle sind „geeigneter Streckenabschnitt und Zeit“ (keine Ergänzung), „unpassende Zeit“, „keine Daten auf Link“ und „keine Daten“. Im Fall „unpassende Zeit“ fehlen lediglich passende zeitspezifische Datensätze an FPKAV. Dann fassen die ergänzten FPKAV alle erfassten

FPKA beliebiger Zeitpunkte auf dem gewünschten Streckenabschnitt zusammen. Liegt darüber hinaus der Fall „keine Daten auf Link“ vor, enthalten die ergänzten FPKAV die Datensätze von zehn „benachbarten Streckenabschnitten“, wenn diese die gleiche Geschwindigkeitsbegrenzung und Straßenart aufweisen. In dem seltenen Fall "keine (benachbarten) Daten" ohne Verfügbarkeit benachbarter Datensätze, beschreiben die ergänzten FPKAV, eine konstante Fahrt mit zulässiger Höchstgeschwindigkeit. [*Dieser übernommene Abschnitt ist zur Einheitlichkeit dieser Arbeit neuformatiert und übersetzt.* © CC BY 131, S. 139]__ Auf Autobahnen ohne Geschwindigkeitsbegrenzung dient die Richtgeschwindigkeit 130 km/h als Ersatz. Dieser Ansatz aus [131] dient hier als Basis für die Ergänzung fehlender Daten.

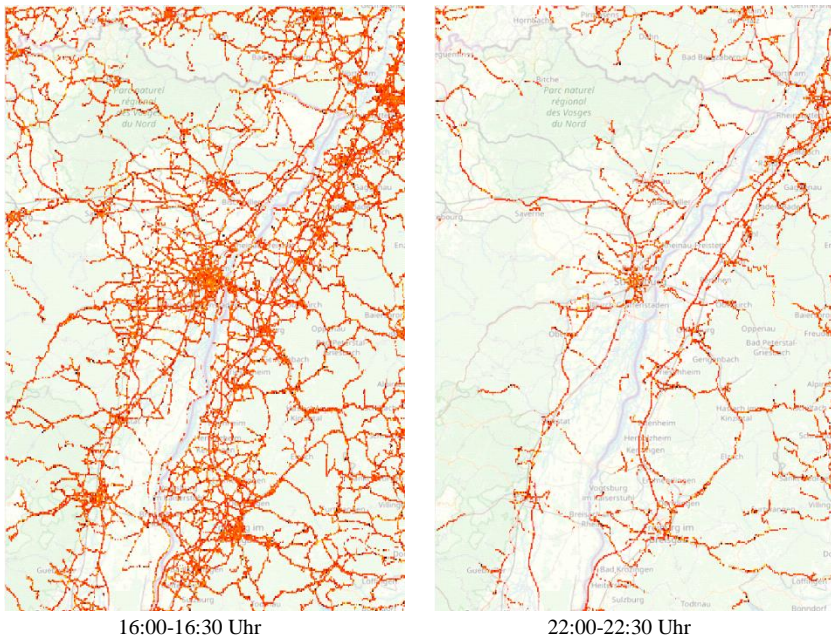


Abb. 6.3: Verfügbarkeit von zeit- und richtungsspezifischen FPKAV zu verschiedenen Zeiten (Karte: ©OpenStreetMap contributors)

Darüber hinaus ist der in [126] favorisierte Datenergänzungsansatz mittels Regression differenzierender. Daher wird [126] nach der folgenden Beschreibung mit dem Basisansatz aus [131] kombiniert. In [126] stützt sich die Ergänzung auf Methoden des supervised Machine Learning, welche Wissen aus den verfügbaren Daten aller Streckenabschnitte verallgemeinern. Dieses Wissen verknüpft die in [126] favorisierte lineare Regression mit aus der digitalen Karte verfügbaren, energetisch relevanten Attributen auf jedem Streckenabschnitt. Diese Attribute erfassen einige Straßeneigenschaften, die das Fahrprofil und somit den Energieverbrauch eines Fahrers auf der Strecke beeinflussen. Dazu nutzt die Regression die Geschwindigkeitsbegrenzung, Straßenklasse, Steigung und Kurvenkrümmung zusammen mit der Zeit und dem Wochentag [126]. Damit kann die Regression in einer Kreuzvalidierung, bis auf einen energetischen Fehler von 12,6 % genau, fehlende Daten ergänzen [126].
___*Übernommener Abschnitt*: Ausgefeiltere Ansätze des Machine Learnings könnten die erzielten Ergebnisse noch weiter verbessern. Solche Modelle könnten sowohl shallow als auch deep Neuronal Networks oder Ensemble-Algorithmen sein, die mit erweiterten Informationen wie Echtzeit-Verkehrsinformationen oder Wetterparametern arbeiten. Diese Ansätze sind jedoch viel rechenintensiver und tendenziell weniger skalierbar. Hier ist jedoch Skalierbarkeit aufgrund der relativ großen Menge an verarbeiteten Daten besonders wichtig. [*Dieser übernommene Abschnitt ist zur Einheitlichkeit dieser Arbeit neuformatiert und übersetzt.* © CC BY 126, S. 20]___

Entsprechend den oben für [131] erläuterten Fällen an fehlenden Daten, lassen sich der Basisansatz [131] und der Regressionsansatz [126] stufenweise kombinieren. Dabei ist die Annahme, dass der Basisansatz für Fälle mit besser passenden Daten bessere Ergebnisse liefern sollte als der generalistische Regressionsansatz. Dagegen sollte Letzterer gerade in Fällen ohne gut passende oder ganz ohne Daten besser funktionieren. Für den Wechsel zwischen den Ansätzen bewertet Abb. 6.4 verschiedene Fälle. Ausgangspunkt ist der Fall, der in (1) das Fahrprofil auf allen Streckenabschnitten einer Route basierend auf dem Regressionsmodell [126] prognostiziert. Gefolgt von den Fällen (2) bis (4), in denen das Regressionsmodell entlang der Route nur für Streckenabschnitte des genannten Falls und Fälle höherer Nummer die FPKAV-Ergänzung übernimmt. Alle anderen Streckenabschnitte werden durch den Basisansatz [131]

mit FPKAV bedient. Der Fall (5) hingegen verwendet für die gesamte Route nur den Basisansatz [131] und nie das Regressionsmodell [126]. Als Grundlage für die Entscheidung, wann der beschriebene Wechsel zwischen diesen beiden Modellen am besten durchzuführen ist, zeigt Abb. 6.4 das Ergebnis der möglichen Kombinationsmöglichkeiten. Dabei liegt eine entsprechend 4.4.1 durchgeführte energetische Fahrprofilprognosebewertung zugrunde, welche aus den Flottendaten ein dem Median entsprechendes Verhalten verwendet.

Die Auswertungsergebnisse in Abb. 6.4 zeigen, dass die rein regressionsbasierte Prognose in (1) zwar tendenziell am wenigsten streut, aber dafür im Median signifikant am schlechtesten ist. Dagegen ist mit mehr gemittelten Daten der Fehler im Median geringer, jedoch nimmt die Streuung tendenziell zu, was sich im IQR zeigt. Insgesamt haben (4) und (5) im Median einen fast auf ein Zehntel reduzierten Fehler und sind dementsprechend ähnlich gut. Während (5) bei der Fahrt eine konstante Geschwindigkeit annimmt, kann (4) auch für Straßenabschnitte ohne Information von Flottenfahrzeugen FPKAV ausweisen. Die im Folgenden Abschnitt 6.2 gezeigte fahrerspezifische Prognose kann jedoch nur mit einer Verteilung von FPKA zwischen Fahrern differenzieren. Um eine fahrerspezifische Prognose immer zu ermöglichen, verwendet die Fahrprofilprognose im Folgenden die Kombination des Regressions- und Basisergänzungsansatzes entsprechend (4) in der Vollausrprägung. Die Paretoausprägung hingegen nutzt im Folgenden nur den Basisansatz, da hier der Rechenaufwand für das Training des Regressionsmodelles im Big-Data-Maßstab entfällt.

Regressionsergänzung wenn:

- (1) immer
- (2) unpassende Zeit
- (3) keine Daten auf Link
- (4) keine (benachbarten) Daten
- (5) nie




Abb. 6.4: Bewertung im MEDPE der stufenweisen Überführung von Datenergänzung mit verwandten Daten zur Regressionsergänzung

6.1.3.2 Umgang mit Datenschutz und -menge

Die in 4.2 beschriebene Energiebedarfsprognose benötigt für jeden Streckenabschnitt die fünf nicht-parametrischen FPKAV. Eine Übermittlung der in 6.1.3 einleitend erläuterten Datenumfänge ins Fahrzeug wäre zum einen teuer und zum anderen nicht immer schnell möglich. Dafür hat [140, betreute Abschlussarbeit] basierend auf Vorüberlegungen von [141, betreute Abschlussarbeit] eine auf unsupervised Machine Learning basierende Kompression erarbeitet. Entsprechend dem Konzept der Vektorquantisierung ermittelt ein Clustering-Algorithmus repräsentative Sets der FPKAV aus dem gesamten Datensatz. Dazu gruppiert das Clustering ähnliche Sets von FPKAV im $36,2 \cdot 10^6$ Kartensegmente umfassenden Testdatensatz. Zur Gruppenzuordnung benötigt das Clustering ein Ähnlichkeitsmaß, das für mehrdimensionale Vektoren, wie den nicht-parametrischen Wahrscheinlichkeitsverteilungen, Divergenz heißt. Der in [140, S. 59] aus energetischer Sicht am besten funktionierende Divergenzansatz ist die Wasserstein-Distanz erster Ordnung [142]. Mit dieser Divergenz kann ein auf diese Datenmengen verwendbares skalierbares „k-means++“-Clustering [143] aus dem Datensatz Gruppen ähnlicher FPKAV ableiten und die FPKAV-Repräsentanten bestimmen. Mit 81 Repräsentanten ist dies mit $-0,79 \pm 3,9\%$ energetischem Fehler der am besten funktionierende Clusteringansatz in [140]. Diese 81 Repräsentanten müssen nur einmalig in das Fahrzeug gesandt werden, da eine Energiebedarfsprognose dann nur die Zuordnungs-Nummern der Repräsentanten je Streckenabschnitt einer Route benötigt. Im Gegensatz zur Übertragung von jeder einzelnen FPKAV spart die zeitlich getrennte Übermittlung von z. B. vierteljährlich aktualisierten 81 Repräsentanten und nur routenbezogenen Zuordnungen 99,9 % an Datenvolumen. Damit ermöglicht diese Clustering-Kompression eine kosteneffiziente Umsetzung im Fahrzeug, was durch reine personenbezogene Datenverarbeitung im Fahrzeug den Datenschutz des im Kapitel 6.2 ermittelten Fahrerverhaltens garantiert, mit überschaubarem Fehler. [140, betreute Abschlussarbeit]

6.1.4 Fazit

Der präsentierte Ansatz zur Erfassung des energetischen Flottenfahrverhaltens kann aus umfangreichen Fahrprofilaten die Verteilung der relevanten

Beschleunigungs-, und Geschwindigkeitseinflüsse in FPKAV erfassen. So ermöglicht dieser Ansatz, anders als z. B. [66; 88–91], auch in nicht parametrischen Verteilungen resultierendes Verhalten zu erfassen. Dies entsteht, wie in Abb. 6.2 erkennbar, bei den einseitig begrenzten IB- und IQG-FPKA aber auch in MG-FPKAV auf mehrspurigen Streckenabschnitten. Trotz der großen Datenmenge zur FPKAV-Erstellung gibt es Strecken- und Zeitabschnitte, zu denen keine passenden Daten vorliegen. Für diese räumlichen und zeitlichen Abschnitte verwendet die Vollausrprägung einen kombinierten Datenergänzungsansatz mit Mittelung ähnlicher Daten und einem Regressionsmodell [126], falls es keine ähnlichen Daten gibt. Die Paretoausrprägung verzichtet auf die Regressionsergänzung, was ähnlich gute Ergebnisse bei weniger Aufwand erlaubt, jedoch auf Strecken ohne verwendbare Daten keine fahrerspezifische Prognose zulässt. Neben der Datenergänzung wäre in einer Fahrzeugumsetzung auch eine Kompression für eine kosteneffiziente Übertragung der FPKAV ins Fahrzeug notwendig. Diese Kompression nutzt die weitere prototypische Bewertung im Folgenden zwar nicht, da der Einfluss des energetischen Fehlers von $-0,79 \pm 3,9\%$ recht gering ist, die prototypische Bewertung auch ohne dies möglich ist und die Konzeptbewertung mit einer Dimension an Unschärfe weniger auskommt. Ob mit oder ohne Komprimierung, fassen die vervollständigten FPKAV das Flottenverhalten als Basis für das folgende Fahrermodell zusammen.

6.2 Fahrerverhalten

Die aggregierte Flottenfahrprofilinformation ist der Ausgangspunkt des Lernens des Fahrerhaltens und damit der fahrerspezifischen FPKA-Prognose. Dazu beschreibt dieses Kapitel das Fahrermodell in 6.2.1 und die Einbindung von Verkehrsinformationen darin in 6.2.2. Damit berücksichtigt das Energiebedarfsprognosemodell, dass Fahrer und Verkehr nach 3 den Energiebedarf stark beeinflussen. Abschließend beschreibt 6.2.3 die dazugehörigen Untersuchungen zur Auswahl der Konfiguration der gesamten Fahrprofilprognose. Entsprechend den Ergebnissen erfolgt die Definition der Voll- und Paretoausrprägung, welche die abschließende Gesamtbewertung nutzt.

6.2.1 Fahrermodell

Ausgangspunkt des Fahrermodells ist das Flottenfahrverhalten, woraus sich direkt das als Basisausprägung dienende Median-Fahrermodell ableiten lässt. Es verwendet zur Fahrprofilprognose nur den am häufigsten beobachteten FPKA-Wert je Streckenabschnitt. Diese Basisausprägung an Fahrermodell ist nicht zu fahrspezifischen Prognosen in der Lage. Dazu sind lernende Fahrermodellansätze notwendig. Prinzipiell lernt das Fahrermodell über zurückliegende Strecken, indem es die Lage (Perzentil u_F) des Fahrverhaltens eines Fahrers innerhalb des Flottenverhaltens (empirische diskrete Wahrscheinlichkeitsfunktionen \tilde{W} der FPKA oder FPKAV) bestimmt. Diese Lage des Fahrerverhaltens nutzt die Prognose und ermittelt aus dem Flottenverhalten der vorausliegenden Strecke die FPKA (Erwartungsperzentilwerte \hat{y}_F). Diese bisher methodisch erläuterte Vorgehensweise des Fahrermodells nutzt dazu die im Folgenden erklärten Methoden der diskreten nichtparametrischen Statistik. Diese Art der Statistik ist notwendig, da die FPKAV (Beispiel: Abb. 6.2), wie 6.1.4 erläutert und auch [98, S. 1407] zeigt, von parametrischen Verteilungsformen wie der der Gauß-Normalverteilung abweichen. Die dazu nötigen statistischen Methoden basieren auf abschnittsweise linearen empirischen Wahrscheinlichkeitsverteilungen [138, S. 655]. Diese Methoden ermöglichen dem Fahrermodell, im nichtparametrischen statistischen Raum des Flottenverhaltens, das Fahrerverhalten anzulernen und zu prognostizieren.

Die FPKAV oder \tilde{W} nach (6.1), welche je Streckenabschnitt das empirisch ermittelte Flottenfahrverhalten enthalten, sind der Ausgangspunkt des Fahrermodells. Gegenüber diesem Flottenverhalten vergleicht das Fahrermodell über die Fahrt je Streckensegment j für alle FPKA die vom Fahrer realisierten Stichprobenwerte Y_F . Wie in 6.1.2 beschrieben, liegen die FPKAV abschnittsweise beschrieben vor. Diese Abschnitte sind mittels Gitterpunkten y_i über den Werteraum der einzelnen FPKA definiert. Zu den Gitterpunkten liegen aus (6.1) die zugehörigen Flottenperzentile u_i vor. Damit ergibt sich entsprechend (6.2) das Fahrer-Perzentil u_F , für eine vom Fahrer gefahrene Stichprobe auf einem zurückliegenden Streckenabschnitt $Y_F[j]$, über lineare Interpolation innerhalb der Flottenperzentile in den FPKAV der Flotte.

$$u_F[j] = \tilde{W}(Y_F[j]) = u_i + (u_{i+1} - u_i) \cdot \left(\frac{Y_F[j] - y_i}{y_{i+1} - y_i} \right) \Big|_{\text{VFPKA}} \quad (6.2)$$

Für i so gewählt, dass $y_i \leq Y_F[j] < y_{i+1}$

$$u_{F,k} = \overline{(u_F[1], u_F[2], \dots, u_F[z])} \Big|_{\text{VFPKA}} \quad (6.3)$$

$$u_F = \frac{\sum_{k=1}^{n_F-1} u_{F,k} \cdot x[z_k]}{\sum_{k=1}^{n_F-1} x[z_k]} \Big|_{\text{VFPKA}} \quad (6.4)$$

Am Ende einer Fahrt k eines Fahrers F bildet (6.3) den Median $u_{F,k}$ je FPKA über alle ermittelten beobachteten Perzentile $u_F[j]$ der z Streckenabschnitte. Dabei ist für die Parameter IBV, IBR, IQGV und IQGR eine Besonderheit zu beachten, da diese für die gesamte Flotte auf einem Streckenabschnitt gleich null sein können. Diese Besonderheit liegt vor, wenn z. B. auf einer Abwärtsstrecke alle Fahrzeuge rekuperieren und somit die Vortriebsparameter IQGV und IBV gleich null sind. Verhält sich ein Fahrer hier wie der Flottenmedian, sagt dies aber wenig darüber aus, ob er sich sonst auf Streckenabschnitten mit Vortrieb wie der Median verhält. Umgekehrtes gilt analog für Strecken mit ausschließlichem Vortrieb in der Flotte. Folglich darf (6.3) nur Streckenabschnitte, welche einen Flottenmedian je FPKA ungleich null haben, zur Fahrerperzentilermittlung $u_{F,k}$ heranziehen. Das vermeidet eine ungewollte Verzerrung des erfassten Fahrerhaltens in Richtung Median. Die so beobachteten Fahrtperzentile $u_{F,k}$ je Fahrt k fasst (6.4) für einen Fahrer F zu einer Gesamtbeobachtung u_F zusammen. Diese Gewichtung nutzt einen mit der Fahrtlänge $x[z_k]$ gewichteten Mittelwert. Dabei meint $x[z_k]$ innerhalb der Fahrt k das Ende des letzten Streckenabschnitts z entlang der Wegpositionen x in einer Route. Dieser beugt im gelernten Fahrerverhalten einer Gewichtung in Richtung kürzer Fahrten vor. Dabei kann die Ermittlung der erwarteten Fahrerperzentile \hat{u}_F entsprechend dem morphologischen Kasten in Abb. 6.5 zusätzlich zur Differenzierung nach FPKA auch nach Straßentypen differenzieren. Hier ist eine Differenzierung nach Autobahn, Überland und innerorts vorgesehen. Damit können die Fahrerperzentilerwartungswerte \hat{u}_F je FPKA beispielsweise erfassen, ob ein Fahrer auf der Autobahn ein anderes Fahrverhalten hat als bei einer Überlandfahrt. Zum anderen kann neben den Straßentypen auch

über Gruppen von FPKA zusammengefasst werden, wie es (6.5) bis (6.7) beschreiben. So kann (6.5) ein Fahrerperzentil für das Beschleunigungsverhalten $\hat{u}_{F,a}$ und (6.6) für das Geschwindigkeitsverhalten $\hat{u}_{F,v}$ ermitteln. Dabei besteht die Annahme, dass ein Fahrer, der tendenziell stark verzögert, auch genauso stark beschleunigt. Neben der Zusammenfassung über Vortrieb und Rekupe-ration hinweg, ist es unter der gleichen Beschleunigungsannahme mit (6.7) möglich, mit einem einzelnen Parameter das erwartete Fahrerperzentil \hat{u}_F zu beschreiben.

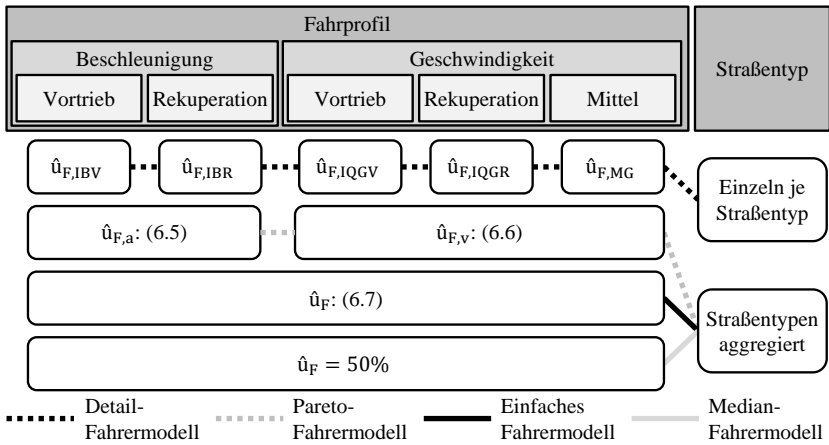


Abb. 6.5: Morphologischer Kasten der Aggregation des Fahrerhaltens

$$\hat{u}_{F,a} = \frac{u_{F,IBV} + (100\% - u_{F,IBR})}{2} \quad (6.5)$$

$$\hat{u}_{F,v} = \frac{u_{F,IQGV} + u_{F,IQGR} + u_{F,MG}}{3} \quad (6.6)$$

$$\hat{u}_F = \frac{u_{F,IBV} + (100\% - \hat{u}_{F,IBR}) + u_{F,IQGV} + u_{F,IQGR} + u_{F,MG}}{5} \quad (6.7)$$

Mit den in Abb. 6.5 beschriebenen Dimensionen des Fahrerhaltens nach Straßentyp und Fahrprofildetails, lassen sich verschieden detailliert lernende Fahrermodelle ableiten. Das Detail-Fahrermodell kann für jedes der fünf

FPKA, sowie die drei Straßentypen separat ein erwartetes Fahrerperzentil \hat{u}_F ausweisen. Somit ist es am spezifischsten bezüglich der Fahrerverhaltensdimensionen. Dagegen reduziert das Einfache Fahrermodell das gesamte Fahrerverhalten auf ein einzelnes erwartetes Fahrerperzentil \hat{u}_F , das nur für IBR entsprechend (6.7) inverse Verwendung findet. Es gäbe dazwischen mehrere mögliche Varianten. Im Folgenden wird jedoch zur Übersichtlichkeit nur ein Pareto-Fahrermodell weiterverfolgt. Das Pareto-Fahrermodell differenziert nur zwischen dem Beschleunigungs- und Geschwindigkeitsverhalten eines Fahrers und nutzt dafür die erwarteten Fahrerperzentile $\hat{u}_{F,a}$ bzw. $\hat{u}_{F,v}$. Neben den angelernten Fahrermodellen zeigt Abb. 6.5 auch das einleitend beschriebene Median-Fahrermodell. Alle Fahrermodelle stellen für die Energiebedarfsprognose die jeweiligen erwarteten Fahrerperzentile für eine strecken- und – bis auf das Median-Fahrermodell – fahrerspezifische Fahrprofilprognose bereit.

$$\hat{y}_F = \tilde{W}^{-1}(\hat{u}_F) = y_i + \frac{\hat{u}_F - u_i}{u_{i+1} - u_i} \cdot (y_{i+1} - y_i) \Big|_{\text{VFPKA}} \quad (6.8)$$

Für i so gewählt, dass $u_i \leq \hat{u}_F < u_{i+1}$

Diese Fahrprofilprognose erfolgt mit (6.8) basierend auf den angelernten, erwarteten Fahrerperzentilen \hat{u}_F als lineare Interpolation, umgekehrt im Vergleich zu (6.2). Diese Fahrprofilprognose liefert basierend auf den FPKAV je Streckenabschnitt die Fahrerperzentilwerte \hat{y}_F aller fünf FPKA. Hier ist wiederum die fürs Lernen beschriebene Besonderheit zu beachten, wenn IBV, IBR, IQGV oder IQGR in der gesamten Flotte streckenbedingt gleich null sind. Für diese liegt aufgrund der Kerndichteschätzung aus 6.1.2 in den FPKAV eine künstliche Verteilung um null vor. Daher muss für alle Streckenabschnitte, auf denen der Flottenmedian einer dieser FPKA null, ist auch der fahrerspezifisch prognostizierte Wert null sein. Dies ist nötig, damit die Fahrprofilprognose nur fahrerspezifische FPKA ausweist, wenn auch eine Streuung in der Flotte vorhanden ist. Damit stellt dieses fahrerspezifische Fahrprofilmodell die nötigen auf dem Flottenverhalten basierenden FPKA für die Energiebedarfsprognose mit den ermittelten Fahrzeugparametern aus 5 zur Verfügung.

6.2.2 Einbindung Verkehrsinformation

Neben dem Fahrer beeinflusst auch der Verkehr das Verhalten aller Fahrer und somit über das Fahrprofil den Energiebedarf eines Elektrofahrzeuges. Dieser Verkehrseinfluss hat Anteile zyklischer, wie durch Berufsverkehr, und zufälliger Art, wie Stau bei Unfällen. Zyklische Anteile berücksichtigen die zeitspezifisch, halbstündlich vorliegenden FPKAV bereits für die fahrerspezifische Fahrprofilprognose. Liegen aber entsprechend 6.1.3.1 keine zeitlich passenden Flottendaten vor, sind die FPKAV weniger spezifisch. Zudem können zufällige Verkehrsereignisse den Energiebedarf beeinflussen. Dazu gehören z. B. unfallbedingte Verkehrsveränderungen. Wenn so eine zufällige Veränderung vorliegt, muss die fahrerspezifische Fahrprofilprognose dies erkennen können. Also konkret, ob sich ein Fahrer auf einem vorausliegenden Streckenabschnitt wie zu dem Zeitpunkt üblich verhalten kann oder ob der Verkehr ihn einschränkt. Dazu ist eine Bezugsgröße notwendig, welche den aktuellen Verkehr beschreibt. Dabei ist die mittlere erwartete Geschwindigkeit auf einem Streckenabschnitt aus der Echtzeitverkehrsinformation (RTTI) üblich [124]. Damit kann die Fahrprofilprognose entscheiden, ob ein übliches oder zusätzlich eingeschränktes Verkehrsgeschehen vorliegt. Dazu dient hier eine Wahrscheinlichkeitsaussage, welche angibt wie, wahrscheinlich die Geschwindigkeit aus RTTI zum normalen Verhalten eines Fahrers bei Überfahrt des vorausliegenden Streckenabschnitts gehört. Diese stellt fest, ob eine signifikante Abweichung der mittleren Geschwindigkeit aus RTTI zu der erwarteten MG aus dem Fahrermodell und seiner Streuung vorliegt. Falls ja, passt das Fahrermodell die prognostizierten FPKA auf den betreffenden Streckenabschnitten an. Wie die Fahrprofilprognose diese Unterscheidung vornimmt, bei Bedarf die FPKA anpasst und somit das erwartete fahrerspezifische Fahrprofil um signifikante Verkehrseinschränkungen korrigiert, beschreibt der folgende Abschnitt methodisch.

Ausgangspunkt der Einbindung von Verkehrsinformationen sind die von einem Serviceprovider [124] verfügbare RTTI-Geschwindigkeit sowie die übliche Verhaltensstreuung eines Fahrers innerhalb der Flotte bezüglich der MG. Es ist also die Wahrscheinlichkeitsverteilung um das erwartete MG-Verhaltensperzentil $u_{F, MG}$ eines Fahrers, das (6.3) je Fahrt beschreibt, über zurücklie-

gende Fahrten nötig. Diese lässt sich als empirische Wahrscheinlichkeitsfunktion $\tilde{W}_{u_F, MG, k}$ je Fahrt k über alle z MG-Perzentil-Stichprobenwerte $Y_{u_F, MG, k}[j]$ mit (6.9) ermitteln [138, S. 653]. Daraus lässt sich im MG-Verhaltensperzentil die Streuung mit der Lage des $IQR_{u_F, MG, k}$ und der unteren Quartilsgrenze $Q1_{u_F, MG, k}$ entsprechend (6.11) bzw. (6.10) beschreiben.

$$\begin{aligned} \tilde{W}_{u_F, MG, k}(y_{F, k}) &= \tilde{P}[Y_{u_F, MG, k} \leq y_{u_F, k}] = \\ \frac{1}{z} \cdot \sum_{[j]=1}^z I[Y_{u_F, MG, k}[j] \leq y_{u_F, MG, k}] \end{aligned} \quad (6.9)$$

$$Q1_{u_F, MG, k} = \tilde{W}_{u_F, MG, k}^{-1}(25\%) \quad (6.10)$$

$$IQR_{u_F, MG, k} = \tilde{W}_{u_F, MG, k}^{-1}(75\%) - \tilde{W}_{u_F, MG, k}^{-1}(25\%) \quad (6.11)$$

Für die Bestimmung des üblichen unteren Verhaltensschwellenwertes des Fahrerperzentiles eines Fahrers F , liefern (6.12) und (6.13) das aus anderen Fahrten übliche 25 %-Perzentil an MG-Fahrerperzentilwerten $Q1_{u_F, MG}$ und die MG-Streuung $IQR_{u_F, MG}$ analog zu (6.4).

$$Q1_{u_F, MG} = \frac{\sum_{k=1}^{n_F-1} Q1_{u_F, k} \cdot x[z_k]}{\sum_{k=1}^{n_F-1} x[z_k]} \quad (6.12)$$

$$IQR_{u_F, MG} = \frac{\sum_{k=1}^{n_F-1} IQR_{u_F, k} \cdot x[z_k]}{\sum_{k=1}^{n_F-1} x[z_k]} \quad (6.13)$$

Nach etwaiger Aggregation je nach Fahrermodell, analog Abb. 6.5, nutzt die Schwellenwertbestimmung die Erwartungswerte $\bar{Q}1_{u_F, MG}$ und $\bar{I}QR_{u_F, MG}$ innerhalb der Flottenverteilung \tilde{W}_{MG} der mittleren Geschwindigkeit MG auf einem Streckenabschnitt $[j]$. Die Entscheidung zwischen der Prognose basierend auf der üblichen historischen Verkehrsgeschwindigkeit $\hat{y}_{F, MG}$ und der Echtzeitverkehrsgeschwindigkeit MG_{RTTI} erfolgt nach (6.14). Dementsprechend fällt, unter Gauss-Normalverteilungsannahme der MG-Fahrerperzentile $u_{F, MG}$

innerhalb des Flottenverhaltens, die Entscheidung nur auf MG_{RTTI} , wenn diese mit einer Wahrscheinlichkeit von 99% außerhalb des üblichen Fahrerverhaltens liegt. Dieser Hypothesentest ist negativ, wenn das Perzentil von MG_{RTTI} , bezogen auf die MG-Flottenverteilung, innerhalb einem 1,4-fachen IQR-Abstand von $\widehat{Q1}_{u_{F,MG}}$ liegt. Tiefer gehende Voruntersuchungen zeigen, dass sich die genaueste Energiebedarfsprognose mit einem 99 %-Signifikanzgrad sowie einer Anwendung nur auf Streckenabschnitten mit FPKAV ergibt, welche auf Flottendaten nicht exakt passender Zeiten basieren, entsprechend 6.1.3.1.

$$\begin{aligned} \widehat{MG}_{RTTI}[j] = & \\ & \hat{y}_{F,MG}[j] \cdot I[\tilde{W}_{MG}(MG_{RTTI})[j] \geq \widehat{Q1}_{u_{F,MG}} - 1,4 \cdot \widehat{IQR}_{u_{F,MG}}] \\ + MG_{RTTI}[j] \cdot I[\tilde{W}_{MG}(MG_{RTTI})[j] < \widehat{Q1}_{u_{F,MG}} - 1,4 \cdot \widehat{IQR}_{u_{F,MG}}] \end{aligned} \quad (6.14)$$

$$\widehat{IQGV}_m = IQGV_o \cdot \frac{\widehat{MG}_{RTTI}^2 \Delta s}{MG_o^2 \Delta s} \text{ mit } IQGV_o = \hat{y}_{F,IQGV}; MG_o = \hat{y}_{F,MG} \quad (6.15)$$


$$\widehat{IQGR}_m = IQGR_o \cdot \frac{\widehat{MG}_{RTTI}^2 \Delta s}{MG_o^2 \Delta s} \text{ mit } IQGR_o = \hat{y}_{F,IQGR} \quad (6.16)$$

Ist jedoch die Echtzeitverkehrsgeschwindigkeit MG_{RTTI} auf einem Streckenabschnitt geringer und die Hypothese, dass eine Verkehrsveränderung vorliegt, ist nicht abzuweisen, sind die FPKA anzupassen. Zunächst ist, wie bereits mit (6.14) beschrieben, für MG die RTTI-Geschwindigkeit zu verwenden. Die anderen beiden Geschwindigkeits-FPKA sind vom ursprünglichen, mit 0 indizierten, Erwartungswert aus (6.8) mit (6.15) für IQGV und (6.16) für IQGR anzupassen [131, S. 140]. Diese Anpassung erfolgt quadratisch, da diese FPKA den Fahrprofileinfluss auf den Luftwiderstand erfassen. Eine Veränderung der beiden Beschleunigungs-FPKA erfolgt nicht, da diese nicht signifikant von MG abhängen [131, S. 140]. Diese FPKA-Anpassungsmethodik ermöglicht es der Fahrprofilprognose, im Falle von relevanten zufälligen Verkehrsereignissen, die Energiebedarfsprognose zu korrigieren.


6.2.3 Ergebnis

Die Ergebnisse zur Genauigkeit des Fahrprofilprognosemodells zeigen den Einfluss der Wahl der beschriebenen Fahrermodellvarianten, der Berücksichtigung von Verkehrsinformation und der Diskretisierung der Straßenabschnitte auf. Dabei basieren die Analysen auf dem in 4.4.2 beschriebenen Vorgehen für Fahrprofilprognosemodelle und nutzen somit das Fahrzeugmodell in Vollausprägung. Die Analyse nutzt die Daten aus 4.4.4 von 26 verschiedenen Fahrern. Damit machen die Ergebnisse sichtbar, wie genau eine Prognose mit dieser Fahrer- und Verkehrsmodellierung kombiniert mit dem Fahrzeugmodell die jeweiligen energetischen Einflüsse erfasst.

Fahrermodell:



Fahrermodell:



Fahrermodell:





Abb. 6.6: Fahrermodellbewertung ohne RTTI anhand MEDPE (oben) und MEDAPE (mittig) in Klemmenenergieverbrauch sowie (unten) MEDPE in mittlerer Geschwindigkeit

Dazu stellt Abb. 6.6 zunächst die Ergebnisse der Genauigkeit der Fahrermodellvarianten ohne Berücksichtigung von RTTI dar. Dabei zeigt (oben) die relative Genauigkeit bezogen auf den Klemmenenergiebedarf an der HVB im MEDPE. Dabei ist zu beobachten, dass alle Modelle außer dem Detail-Fahrermodell (2) signifikant zu niedrige Energiebedarfe prognostizieren, auch wenn die Unterschiede der Medianwerte nicht signifikant sind. Im Medianwert ist das Detail-Fahrermodell dennoch fast ein Drittel besser als andere. Bezüglich Streuung ist zwar die des Einfachen Fahrermodells (4) tendenziell am kleinsten, jedoch streut das Detail-Fahrermodell nur marginal mehr. Zudem hat das Median-Fahrermodell (1) am meisten Streuung, was der in (mittig) dargestellten MEDAPE auch für die absolute Genauigkeit zeigt. Dagegen ist das Detail-Fahrermodell hier als einziges in Medianwert und IQR tendenziell am besten. Die Unterschiede sind hier zwar gering und wiederum nicht signifikant, aber gerade im IQR ist (2) dennoch ein wenig besser als das nächstschlechtere Einfache Fahrermodell. Im Gegensatz dazu ist das Ergebnis für Streckenabschnittsgeschwindigkeit MG bezüglich des relativen MEDPE in (unten) klarer. So hat das Detail-Fahrermodell hier bei ähnlichen Streuungen im Median einen signifikant um dreiviertel geringeren Fehler als die anderen Fahrermodelle.

Verkehrsmodell:

- (1) ohne RTTI; n=233
 (2) mit RTTI; n=86



Verkehrsmodell:

- (1) ohne RTTI; n=233
 (2) mit RTTI; n=86




Abb. 6.7: Gegenüberstellung Detail-Fahrermodell mit und ohne Verkehrsberücksichtigung in MEDPE (oben) und (unten) MEDAPE bezogen auf Klemmenenergieverbrauch

Über die meisten Kriterien hinweg ist also das Detail-Fahrermodell (2) mit seiner Differenziertheit im Verhalten sowohl bezüglich Straßentypen als auch

Fahrprofildimensionen am genauesten. Deswegen greift die Vollaussprägung für eine möglichst genaue Energiebedarfsprognose auf das Detail-Fahrermodell zurück und ist auch Grundlage für die Bewertung der Einbindung von Verkehrsinformationen. Jedoch ist gerade das Einfache Fahrermodell (4) im MEDAPE, welcher ohne Fehlerneutralisationen am zuverlässigsten ist, in Median und Streuung nur marginal schlechter. Da es statt 15 Fahrerparametern jedoch nur einen Parameter anlernt und somit deutlich weniger aufwendig ist, verwendet das Paretomodell das Einfache Fahrermodell (4).

Die Ergebnisse mit und ohne Einbindung von Verkehrsinformationen in Abb. 6.7 stammen von Prognosen basierend auf dem Detail-Fahrermodell entsprechend der Vollaussprägung. Dabei zeigt Abb. 6.7, anders als bisherige Abbildungen, auch Ausreißer. Zudem liegen für die Prognose mit RTTI (2) nur Ergebnisse von weniger Fahrten vor als ohne RTTI (1), da nur für diese Fahrten mit aktiver Routenführung nach 4.4.4 RTTI vorliegt. Zum relativen MEDPE zeigt Abb. 6.7 (oben), dass die Prognose mit RTTI (2) zwar im Median signifikant zu geringe, aber nicht signifikant schlechtere Ergebnisse als ohne RTTI (1) bringt. Dabei ist insbesondere auffällig, dass die Prognose mit RTTI (2) gerade sehr hohe Streuungsfälle und Ausreißer reduziert. Diese Reduktion, gerade von großen Fehlern mit positivem Vorzeichen, ist damit zu erklären, dass etwaige vom Fahrer im dichten Verkehr nicht fahrbare, signifikant zu hohe Geschwindigkeitsprognosen auf RTTI-Niveau reduziert werden. Dagegen ermöglicht RTTI hier aber nicht, Geschwindigkeiten höher als üblich laut Flottenverhalten anzuheben. Zusammen führt dies zu einem tendenziell geringeren Energiebedarf, was ein Vergleich der Mediane im MEDPE zeigt. Jedoch fängt die Einbindung von RTTI hohe Extremfälle ab, was in einer tendenziell geringeren Streuung im MEDPE resultiert. Die gesamthafte Bewertung von Streuung und Medianfehler zeigt Abb. 6.7 (unten) im MEDAPE. Diese deutet darauf hin, dass die reduzierte Streuung des Prognosemodelles mit RTTI (2) im MEDAPE den schlechteren MEDPE-Median tendenziell überkompensieren kann, wenn auch nicht signifikant. So ist der Median des MEDAPE mit RTTI (2) mit $12,5 \pm 2,6$ % besser als ohne RTTI (1). Darüber hinaus sind die höchsten Ausreißer und das 75 %-Perzentil tendenziell geringer. Folglich sollte die Fahrprofilprognose RTTI, gerade bei durch Verkehr extrem verlangsamter Geschwindigkeit, für eine verbesserte Energiebedarfsprognose nutzen und somit

in der Vollaussprägung Anwendung finden, jedoch im Paretomodell wegen des Aufwands nicht.

Neben den bisher gezeigten Ergebnissen zur Fahrer- und Verkehrsberücksichtigung ist für das Fahrprofilmodell zu überprüfen, ob die Diskretisierung der Route auf Streckenabschnitte entsprechend der Karte einen Einfluss auf die Genauigkeit hat. Dies hat zwar [125] entsprechend 6.1.2 zwar schon analysiert, jedoch soll die Auswertung mit dem hier vorliegenden Datensatz die Ergebnisse belegen. Dazu zeigt Abb. 6.8 den Vergleich einer feinen und groben Diskretisierung der Route in Streckenabschnitte für die Energiebedarfsprognose, hier in Vollaussprägung für Fahrzeug- und Fahrprofilmodell. Dabei zeigt diese Fahrprofilmodellbewertung entsprechend 4.4.2 qualitativ ähnliche Ergebnisse wie [125]. So sind die Medianwerte nicht signifikant unterschiedlich, aber die Diskretisierung in Streckenabschnitte entsprechend der digitalen Karte streut tendenziell weniger als mit 50 m Sublinks. Hier streut das Ergebnis um 10,1 % mehr bei feinerer Einteilung der Route entsprechend der Karten, jedoch nicht längeren Streckenabschnitten bzw. Sublinks als 50 m. Damit deutet die Analyse in Abb. 6.8, dass die zu favorisierende Diskretisierung in Streckenabschnitte entsprechend der digitalen Karte, wie in 6.1.2 basierend auf [125] vorgeschlagen, bei weniger Speicherbedarf durch stärkere Aggregation ähnlich genau bleibt.

Segmentierung:




Abb. 6.8: Einfluss Diskretisierung entsprechend Karte oder zusätzlichen 50 m Sublinks

6.2.4 Fazit

Der Zweck des Fahrermodells mit ergänzendem Verkehrsmodell ist es, die Varianz der entsprechenden Einflüsse auf den Energiebedarf vorherzusagen, da die Sensitivitätsuntersuchung in 3.5 deren Relevanz belegt. Dazu zeigen die

Analysen in Abb. 6.6 (oben), dass das Detail-Fahrermodell (2) die Streuung der MEDPE-Prognosefehler ausgehend vom Median-Fahrermodell (1) ein wenig reduziert. Darüber hinaus kann das ergänzende Verkehrsmodell mit RTTI diese Verbesserung im IQR deutlich verstärken, auch wenn der systematische Fehler im Median – allerdings nicht signifikant – schlechter ist, entsprechend Abb. 6.7 (oben). Damit deuten die Ergebnisse darauf hin, dass das Detail-Fahrermodell mit ergänzendem Verkehrsmodell einen wesentlichen Anteil der in 3.5 festgestellten relevanten Einflüsse im Energiebedarf erfassen kann. Folglich verwendet die Vollaussprägung der Energiebedarfsprognose im Folgenden das Detail-Fahrermodell zusammen mit dem Verkehrsmodell, soweit in den Daten RTTI vorliegt. Diese Modellkombination ist mit $12,5 \pm 2,6\%$ im MEDAPE tendenziell genauer als alle anderen Fahrprofilmodelle, wenn auch nicht signifikant.

Da diese Fahrermodellierung mit einigem Aufwand verbunden ist, verwendet das Paretomodell der Energiebedarfsprognose nur das einfache Fahrermodell (4) ohne RTTI. So ist keine Anbindung an einen RTTI-Provider notwendig und das Fahrermodell lernt nur einen Parameter statt 15. Damit ist der MEDAPE deutlich ungenauer und die Streuung im MEDPE-IQR deutlich größer, jedoch ist der Aufwand des Paretomodells viel geringer, was 7.2 quantifiziert.

Abgesehen von Kombinationen der Fahrprofilprognosevarianten mit in dieser Arbeit entwickelten Fahrzeugmodellvarianten, ist mit den Ergebnissen aus Abb. 6.6 (unten) eine weitere interessante Zusammenstellung möglich. So zeigt das Detail-Fahrermodell vielversprechende Ergebnisse für die MG. Dieser energetische Fahrprofilparameter ist die alleinige Eingangsgröße von [80], welches unter den Literaturmodellen in Abb. 5.6 die besten Fahrzeugmodell-ergebnisse zeigt. Daher beinhalten die folgenden Analysen auch die möglicherweise vielversprechende Kombination des Antriebsmodelles von [80] mit dem Detail-Fahrermodell ohne RTTI entsprechend Abb. 6.6.

7 Bewertung Routenenergiebedarfsprognose

Das Ziel der Arbeit ist es, den Energiebedarf entlang von Routen als Grundlage für energetisch planende Anwendungen präzise vorherzusagen. Dabei muss die Energiebedarfsprognose die relevanten Einflüsse aus 3.5 erfassen. Wie präzise die bis hierhin erläuterten und anhand der Teilergebnisse ausgewählten Fahrzeug- und Fahrprofilmodellvarianten gesamthaft zusammenspielen, fasst der folgende Abschnitt zusammen. Dazu verschafft zunächst 7.1 einen Überblick über die zuvor erarbeiteten Modellausprägungen und die Vergleichskandidaten aus der Literatur. Für diese Modelle bewertet 7.2, welche energetische Präzision sich bei welchem rechnerischen Aufwand erreichen lässt. Entsprechend dieser Bewertung erläutert 7.3 Empfehlungen für die praktische Umsetzung einer Energiebedarfsprognose für Routen.

7.1 Übersicht Teilmodelle

Die vorangegangenen Kapitel erläutern unterschiedliche Ausprägungen der Teilmodelle, welche sich kombinieren lassen. Über diese Ausprägungen verschafft der Morphologische Kasten in Abb. 7.1 einen systematischen Überblick. Der Morphologische Kasten stellt dazu in Spalten die Hauptbestandteile einer Energiebedarfsprognose dar. Dazu fassen die linken beiden Spalten die Antriebsmodellvarianten zusammen und differenzieren, falls trennbar, nach Fahrwiderstands- und Effizienzmodellausprägung. Ebenfalls als Teil des Fahrzeugmodells listet die rechte Spalte die Varianten des für die Nebenverbraucher relevantesten Teilmodells der Temperierung. Die Spalte dazwischen zeigt die Ausprägungen des Fahrprofilmodelles, welches die Eingangsgrößen für die Fahrzeugmodellausprägungen bereitstellt. Dabei zeigt der Morphologische Kasten grau hinterlegt Hauptausrägungen aus 5.1 zu den Antriebsmodellen,

aus 5.2.1 zu Temperierungsmodellen und aus 6 zu Fahrprofilmodellen. Zudem sind, weiß hinterlegt, Literaturvarianten enthalten. Zum Überblick welche Modellausprägungen die Bewertung in Abb. 7.3 einschließt, fassen die folgenden Absätze die Resultate der Diskussionen der vorherigen Teilmodell-Kapitel zusammen, entsprechend dem Morphologischen Kasten in Abb. 7.1.

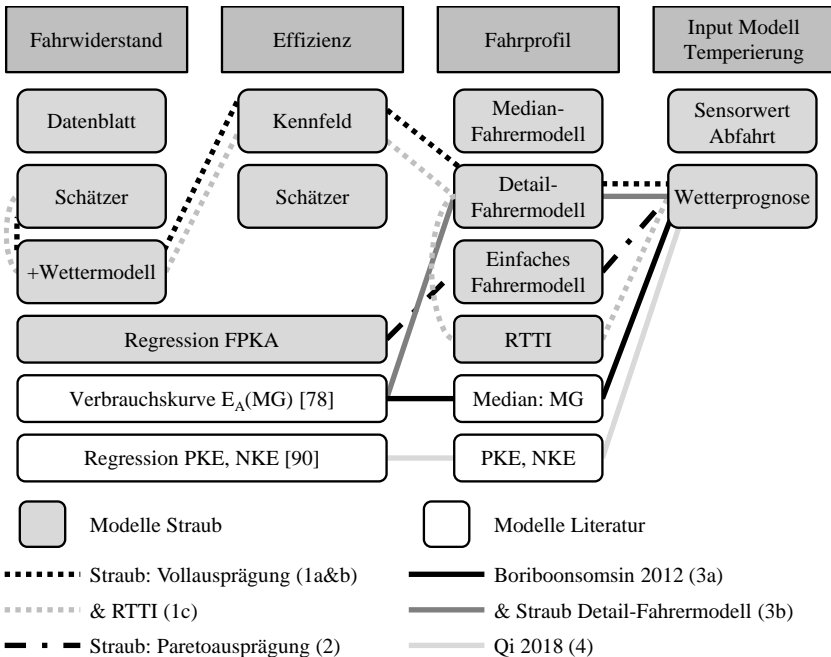


Abb. 7.1: Morphologischer Kasten verschiedener Energiebedarfsprognoseausprägungen

Die Vollausrprägung (1) stellt die genaueste physikalische Energiebedarfsprognosevariante in dieser Arbeit dar und zeigt die Möglichkeiten detailreicher Modellierung. So nutzt das lernende Fahrwiderstandsmodell darin einen RLSmf-Fahrwiderstandsschätzer mit vorgelagerter PKS Signalvorverarbeitung [35; 110; 112] sowie Prognoseanpassungen basierend auf Wettervorhersagen entlang der Route [120]. Dabei bedeutet die Benennung (1a), dass die gesamte Fahrt untersucht wird. Dagegen betrachtet (1b) die Fahrt nur ab der Konver-

genz des Schätzers nach spätestens 10 *km*. Das zur Komplettierung des Antriebsmodells notwendige Effizienzmodell verwendet Kennfelder entsprechend [122, S. 103–104]. Das Fahrzeugmodell wird ergänzt durch das Temperierungsmodell, das ebenfalls Informationen aus der Wettervorhersage [120] nützt. Daneben prognostiziert das rein extrapolierende Modell aus 5.2.2 den verbleibenden Nebenverbrauch im Fahrzeugmodell in dieser und allen folgenden Ausprägungen. Dieses Fahrzeugmodell benötigt als wichtigste Eingangsgröße die in 4.3 hergeleiteten FPKA, welche das Fahrprofilmodell basierend auf Flottendaten bereitstellt. Darüber hinaus nutzt das Fahrprofilmodell der Vollaussprägung zur fahrerspezifischen Prognose das in 6.2.1 beschriebene Detail-Fahrermodell. Zudem ergänzen Echtzeitverkehrsinformationen in (1c) die Fahrprofilprognose, wenn genügend Daten für die Fahrt verfügbar sind. Somit ermöglicht die Vollaussprägung eine strecken-, fahrt- und fahrerindividuelle Energiebedarfsprognose mit wetter- und verkehrsspezifischen Korrekturen.

Die Paretoausprägung (2) nutzt die im Aufwand effizientesten Stellhebel für eine etwas weniger präzise, dafür jedoch mit weniger Rechenaufwand und Schnittstellen verbundene Energiebedarfsprognose. Dazu ersetzt eine lineare Regression über die FPKA das in der Vollaussprägung (1) zweiteilige Antriebsmodell, was entsprechend 5.1.3 kaum ungenauer ist. Das Fahrzeugmodell wird durch das Temperierungsmodell vervollständigt, welches wiederum eine Wettervorhersage [120] nutzt, da dies in 5.2.1.2 ein signifikant präziseres Ergebnis zeigt. Dieses Fahrzeugmodell benötigt wiederum die in 4.3 hergeleiteten FPKA, welche das Fahrprofilmodell basierend auf Flottendaten bereitstellt. Hierzu nutzt das Fahrprofilmodell der Paretoausprägung zur fahrerspezifischen Prognose das in 6.2.1 beschriebene Pareto-Fahrermodell. Dieses ist mit einem statt 15 Parametern weniger aufwendig, kann aber dennoch fahrerspezifisch prognostizieren. Damit ermöglicht die Paretoausprägung eine etwas weniger strecken-, fahrt- und fahrerindividuelle Energiebedarfsprognose mit wetterspezifischen Anpassungen, jedoch mit geringerem Rechenaufwand.

Die Bewertung stellt, basierend auf denselben Flottendaten als Prognosegrundlage, den auf FPKA basierenden Energiebedarfsprognosevarianten dieser Arbeit auch zwei relevante Ansätze aus der Literatur gegenüber. Zum einen benötigt das Antriebsmodell (3) von Boriboonsomsin [80] für die Verbrauchs-

kurve die in den bereits FPKA enthaltene MG. Diese Verbrauchskurve deckt nur den Antrieb ab. Die folgende Bewertung soll nur den Unterschied zu dem von Boriboonsomsin [80] beschriebenen Modellumfang ausweisen. Daher nutzt das Fahrzeugmodell (3) auch das Temperierungsmodell mit Wettervorhersage [120] sowie das rein extrapolierende Modell für andere Nebenverbraucher aus 5.2.2. Diese Nebenverbrauchermodelle benötigen wie das ganze Fahrzeugmodell nur die MG als Fahrprofileingangsgröße. Dazu schlägt [80] ebenfalls die Nutzung von zeitspezifischer Flotteninformation vor, geht aber auf kein Fahrermodell ein. Somit nutzt (3a) den Median der halbstündlich aufgelösten Flottengeschwindigkeit je Streckenabschnitt. Darüber hinaus ist das Detail-Fahrermodell entsprechend 6.2.3 signifikant am besten in der MG-Prognose. Daher nutzt (3b) das Detailfahrermodell, um einen möglichen Präzisionsgewinn für das erste gegenübergestellte Literaturmodell von Boriboonsomsin [80] auszuweisen. Das zweite gegenübergestellte Literaturmodell (4) unterscheidet sich von (3a) nur im verwendeten Antriebsmodell, das von Qi stammt [1]. Hier nutzt eine lineare Regression die *PKE* und *NKE* als Fahrprofilinformation. Diese ist ausgehend vom teststreckenbasierten Ansatz in [1] auf einen karten- und flottenbasierten Ansatz erweitert. Dabei sind die *PKE* und *NKE* als Median aus den vorliegenden Flottendaten ermittelt. Damit kann die folgende Bewertung den Modellvarianten dieser Arbeit auch zwei Literaturmodelle gegenüberstellen und zudem deren Verwendbarkeit bei Ausrollung auf umfangreiche Flottendaten aufzeigen.

7.2 Modellvergleich

Für die im Morphologischen Kasten in Abb. 7.1 zusammengefassten Modellausprägungen, zeigen Abb. 7.2 und Abb. 7.3 die Ergebnisse aus deren Bewertung. Dabei erfolgt die Bewertung zunächst als relative Rechenaufwandsvergleich. Danach folgt die Bewertung entsprechend 4.4 mit Fokus auf die Präzision im Vergleich zum im Fahrzeug aufgezeichneten Klemmenenergiebedarf E_{HVB} entlang der der Einzelfeldfahrten entsprechend 4.4.4. Dieser umfasst, neben den in dieser Arbeit entwickelten Modellen, Ansätze aus der Literatur sowie Kombinationen davon. Damit bilden die Betrachtungen eine umfassende

Beurteilungsgrundlage bezüglich Genauigkeit und dem dazu notwendigen Rechenaufwand für danach folgende Umsetzungsempfehlungen.

Mit Blick nur auf den Rechenaufwand zeigt Abb. 7.2 zwei Gruppen mit ähnlichem Aufwand. Dabei basiert die Bewertung auf der mittleren Dauer von zehn Prognoserechnungen – was mögliche andere Einflüsse auf die Rechenzeit ausmitteln soll – der mit 203,3 km längsten Fahrt, die damit den meisten Rechenaufwand unter den Fahrten mit sich bringt. Dabei benötigt die Berechnung für die Vollaussprägung (1a-c) gut um die Hälfte länger als die anderen Modelle. Diesen zusätzlichen Rechenaufwand verursacht entsprechend Detailanalysen v. a. die Fahrwiderstandsschätzung. Der Rechenaufwand der anderen Modelle (2-4) unterscheidet sich maximal um 2,2 Prozentpunkte. Das zeigt, dass die Modellvariation hier weniger die Rechenzeit beeinflusst. Die meiste Zeit beansprucht die den Modellen (2-4) gemeinsame Berechnung der Temperierungsprognose mit Wetterprognose und der Umgang mit den umfangreichen Flottendaten. Zusammengefasst zeigt sich, dass die zusätzliche Rechenzeit für die Vollaussprägung (1c) die Energiebedarfsprognose die physikalischen Zusammenhänge besser abbilden lässt, dass aber die Ausprägungen (2-4) jedoch kaum Aufwandsunterschiede aufweisen.

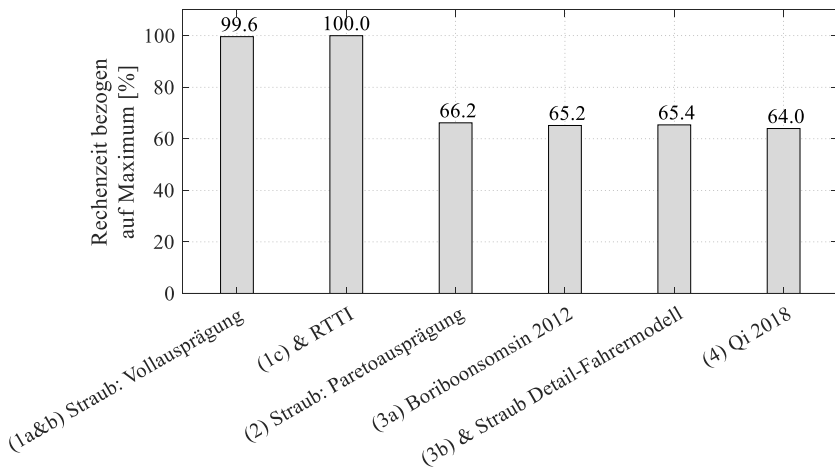


Abb. 7.2: Relative Rechenzeit der Konzepte bezogen auf Maximalwert

Mit dem MEDPE zeigt Abb. 7.3 (oben) zunächst die Bewertung der energetischen Genauigkeit im relativen Fehler. Dabei zeigt sich, dass nur (1b) und (3b) nicht signifikant ungleich null sind. Darüber hinaus hat (1b) mit $-2,2 \pm 2,8$ % den geringsten Medianfehlerwert. Wobei sich nach Anlernen der Fahrwiderstandsschätzung zwischen (1a) und (1b) der beobachtete Fehler im Medianwert halbiert, jedoch auch etwas mehr im IQR streut. Dabei zeigen alle auf den FPKA basierenden Modelle zumindest tendenziell zu niedrige Werte, wenn auch nicht alle signifikant sind. Das liegt für (1a) insbesondere an der Basisausprägung, die bis zur Konvergenz der Fahrwiderstandsschätzung aktiv ist und entsprechend 5.1.1.5 zu wenig Verbrauch prognostiziert. Dementsprechend ist (1b) mit gelernten Fahrwiderstandsparametern nicht mehr signifikant zu niedrig. Jedoch führt die Reduktion der Geschwindigkeit durch RTTI in (1c) wiederum zu einem zu niedrigen Medianwert, was aber auch die Streuung etwas reduziert. In der gemeinsamen Wertung von Streuung und Erwartungswert mit dem MEDAPE zeigt Abb. 7.3 (unten) letztendlich, dass die beiden Modellabstufungen von (a) auf (b) bzw. (c) den Medianwert jeweils verbessern, wenn auch nicht signifikant. Damit zeigt die konvergierte Vollaussprägung (1c) mit Verkehrsanpassung die in dieser Stichprobe besten Ergebnisse unter den betrachteten Ausprägungen. Dagegen heben sich die Ergebnisse der Paretoausprägung (2) im MEDPE nicht von den anderen Modellen ab. Jedoch liegt (2) im MEDAPE-Medianwert zwischen (1b) und (1c) und der IQR ist tendenziell kleiner als für jegliche Vollaussprägungsbewertungsvariante, anders als im MEDPE. Betrachtet man aber die von den Whiskern begrenzten rechnerisch inneren 99,7 %, so streut (1c) im MEDPE tendenziell weniger bzw. der obere MEDAPE-Whisker ist hier immer kleiner als für alle anderen Modelle. Damit zeigt sich, dass die detailliertere Vollaussprägung der Energiebedarfsprognose insbesondere extreme Einflüsse besser erfassen kann. Dagegen schneidet die entsprechend Abb. 7.2 ein Drittel weniger aufwendige Paretoausprägung durch vereinfachte Einflussmodellierungen, wie erwartet, etwas schlechter ab.

Mit Blick auf die Literaturmodelle zeigt Abb. 7.3 (oben) zunächst für das Modell (3a) von Boriboonsomsin [80] eine, im Gegensatz zu den FPKA-basierten Modellen, signifikante Überschätzung des Energiebedarfs. Das liegt womöglich daran, dass die Rekuperation durch die implizite Berücksichtigung unterrepräsentiert ist. Auch die IQR-Streuung von (3a) ist im MEDPE tendenziell

größer als für die Vollaussprägung (1c). Wobei gerade Extremfälle um fast ein Drittel zusätzlich streuen, was sich mit den von den Whiskern begrenzten inneren 99,7 % zeigt. Das zeigt auch Abb. 7.3 (unten) für Extremfälle mit fast einem Fünftel Unterschied im oberen MEDAPE-Whisker, wobei jedoch die IQR-Streuung für (1c) und (3a) gleich groß ist. Insbesondere in der aussagekräftigsten Kenngröße für Streuung und systematische Fehler, dem MEDAPE-Medianwert, ist das Boriboonsomsin-Modell (3a) fast ein Fünftel schlechter als die Vollaussprägung (1c). Der Unterschied ist erklärbar mit der nur implizit erfassten Beschleunigung in der Verbrauchskurve über MG und einer fehlenden fahrerspezifischer Prognose.

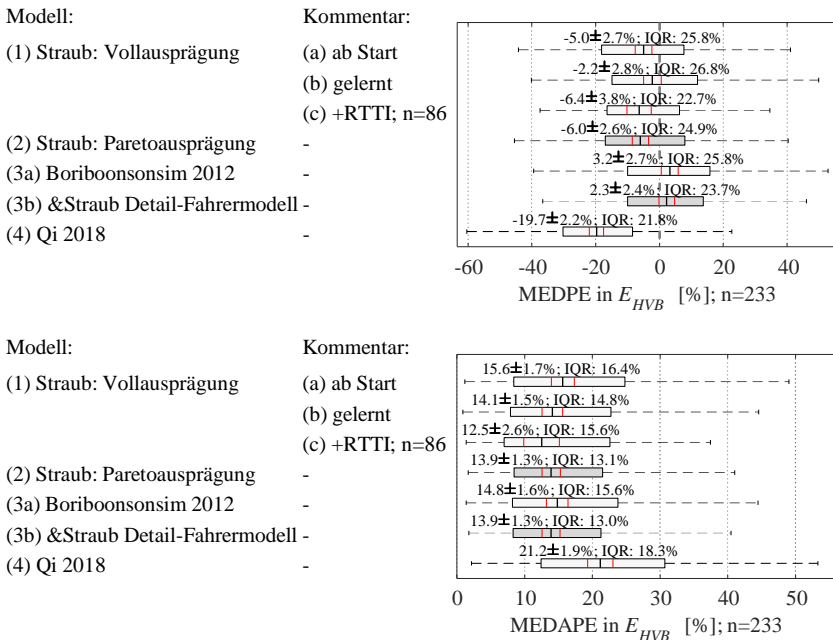


Abb. 7.3: MEDAPE (oben) und MEDAPE (unten) verschiedener Energieprognoseausprägungen

Eben diesen Fahrereinfluss adressiert die Kombination (3b) des Boriboonsomsin-Antriebsmodells [80] mit dem Detail-Fahrermodell aus 6.2.1. So zeigt

Abb. 7.3 (oben), dass die Energiebedarfsprognose dadurch mit einem fast ein Drittel geringeren MEDPE-Medianwert nicht mehr signifikant zu hoch ist. Zudem sinkt tendenziell die IQR-Streuung. Diese beiden Verbesserungen resultieren auch in etwas, wenn auch nicht signifikanter, Verbesserung zwischen (3a) und (3b) in der Hauptkenngröße MEDAPE-Medianwert in Abb. 7.3 (unten). Damit zieht das Kombinationsmodell (3b) in der Präzision mit der Paretoausprägung (2) gleich. Zwar muss das Kombinationsmodell (3b) im Fahrermodell mit drei Parametern umgehen statt mit einem einzelnen im Paretomodell (2), dafür benötigt das Paretomodell aber fünf FPKAV aus der Flotte statt nur der MG für (3b). Das Resultat zeigt Abb. 7.2, dementsprechend rechnet das Kombinationsmodell (3b) geringfügig schneller bei vergleichbarer Genauigkeit.

Im Gegensatz dazu ist das Modell (4) nach Q_i [1] nicht nur signifikant zu niedrig, sondern auch der gesamte beobachtete IQR liegt unter null. Dadurch ist (4) auch signifikant niedriger als alle anderen Modelle. Dazu zeigt die kombinierte Bewertung von Streuung und Medianfehler in Abb. 7.3 (unten), dass der MEDAPE-Medianwert um über ein Drittel höher liegt als der aller anderen Modelle, trotz geringster IQR-Streuung im MEDPE in Abb. 7.3 (oben). Das schlechte Ergebnis im MEDAPE-Medianwert ist also durch die signifikant zu niedrige Energiebedarfsprognosen von (4) erklärbar. Dieses zu niedrige Ergebnis in der Gesamtprognose steht teilweise im Gegensatz zu den Antriebsmodellergebnissen in 5.1.3. So ist das Modell (4) von Q_i zwar im MEDAPE-Medianwert auf Antriebs- und Fahrzeugebene, entsprechend Abb. 5.7 (unten) bzw. Abb. 7.3, das ungenaueste, jedoch hat es in der Antriebsmodellbewertung im MEDPE den geringsten Medianwert aber die größte IQR-Streuung, entsprechend Abb. 5.7 (oben). Das dreht sich in der Gesamtbewertung um, wie oben erläutert. Da die Antriebsmodellbewertung aber mit den aufgezeichneten Sollfahrprofilinformationen erfolgt, zeigt sich, dass die flottenbasierte Fahrprofilprognose in dem Modell von Q_i zu den systematisch zu geringen Energiebedarfsprognosewerten führt. Somit ist das Modell (4) von Q_i trotz der höchsten Recheneffizienz, entsprechend Abb. 7.2, nicht für eine Umsetzung zu favorisieren.

7.3 Umsetzungsempfehlungen

Die gezeigten Bewertungsergebnisse bezüglich Präzision und Aufwand der verschiedenen Energiebedarfsprognosemodelle lassen für verschiedene Anwendungsfälle unterschiedliche Auswahlen zu, welche Tab. 7.1 zusammenfasst. So können sich die Anwendungsfälle in ihrem vornehmlichen Ziel entweder auf eine genaue oder eine effiziente Prognose fokussieren. Dabei ist auch die zur Verfügung stehende Recheninfrastruktur entscheidend. So sind die Rechenkapazitäten im Fahrzeug eingeschränkter und deshalb steht Recheneffizienz mehr im Vordergrund. Dagegen ist bei einer Berechnung vollständig oder, wie in 4.2 vorgeschlagen, teilweise extern in einem Backendserver mehr Rechenkapazität verfügbar. Ist z. B. im Fahrzeug ein möglichst recheneffizientes Modell notwendig, so ist entsprechend Abb. 7.2 sowie Abb. 7.3 (unten) das Modell nach Boriboonsomsin [80] zusammen mit dem flottenbasierten Detail-Fahrermodell zu verwenden. Wobei bei Fahrzeugen für eher innerstädtische Anwendung, entsprechend Abb. 7.4, auch eine Energiebedarfsprognose in Paretoausprägung sinnvoll ist, bei geringfügig mehr Rechenaufwand. Ist die Rechenleistung, wie bei einer reinen Backendanwendung, weniger eingeschränkt und auch die Anbindung von Verkehrsdaten einfacher, so liefert die Energiebedarfsprognose in der Vollausprägung zusammen mit RTTI in alleinständiger Anwendung die präziseste Vorhersage, wie Abb. 7.3 (unten) zeigt. Dennoch zeigt Abb. 7.4, dass die Modelle auf verschiedenen Straßentypen unterschiedlich gut funktionieren. So ist je nach Hauptanwendungsgebiet des Fahrzeuges oder aber auch streckentypspezifisch eine andere Energiebedarfsprognose denkbar, wie Tab. 7.1 zusammenfasst. Hier fokussieren sich die Überlegungen jedoch auf die gesamthafte Umsetzung eines Modelles, um die Betrachtungen übersichtlicher zu halten. Tab. 7.1 ermöglicht dem Leser allerdings spezifische Schlüsse bezüglich der Energiebedarfsprognose für seine Anwendung zu ziehen, um für den Fahrer das beste Ergebnis bereitzustellen.

Tab. 7.1: Umsetzungsempfehlungen

Hauptanwendungsgebiet	Verfügbare Rechenkapazitäten	
	groß	gering
Gesamthaft	(1c)	(3b)
Stadt	(2)	(2)
Land	(3b)	(3b)
Autobahn	(1c)	(3b)

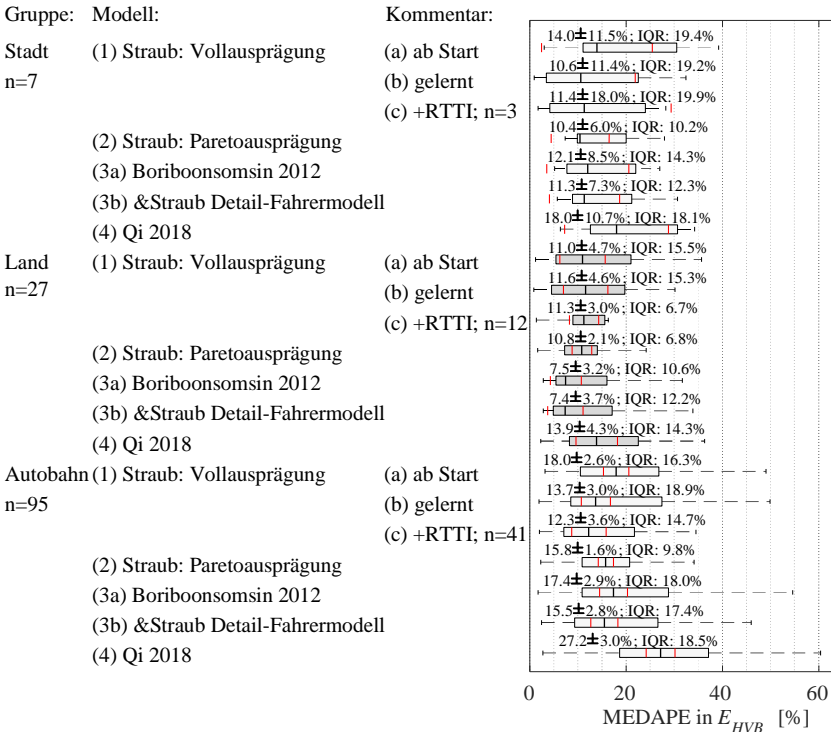


Abb. 7.4: MEDAPE verschiedener Energieprognoseausprägungen nach Validierungsgruppen

8 Anwendungen

Die gezeigte flottendatengestützte Energiebedarfsprognose kann für vielfältige Anwendung nützlich sein, wie in 1.1 angedeutet. Zunächst veranschaulicht 8.1 die aufbereiteten Flottendaten in einem Energie-Kartenlayer. Basierend auf dieser Karte mit energetischer Flotteninformation zeigte 7.2 bereits die Präzision, mit der sich der Energiebedarf prognostizieren lässt. Jedoch bringt der vorhergesagte Verbrauch für den Fahrer während der Fahrt erst in weiterverarbeiteter Form einen Mehrwert. Dazu zeigt 8.2 wie präzise eine auf den Energiebedarfsprognosemodellen aufbauende Reichweitenberechnung für gegebene Routen ist. Andererseits zeigt 8.3, wie eine Routingfunktion insbesondere für Routen, die länger als die verfügbare Reichweite sind, eine möglichst schnelle Ankunft am Ziel ermöglichen kann. Diese Anwendungen geben einen Ausblick auf die mögliche Verwendung der Energiebedarfsprognose.

8.1 Energie-Kartenlayer

Basierend auf den Flottendaten aus 6.1.1 zeigt Abb. 8.1 einen Ausschnitt eines Energie-Kartenlayers gemittelt für alle Tageszeiten. Dabei kann dieser Kartenlayer die digitale Karte um energetische Information erweitern, entsprechend Anhang A.1. Dazu zeigen die Farben in Abb. 8.1 den Energieverbrauch eines Medianfahrers, hier berechnet für den BMW i3. Ein dunkelroter Straßenabschnitt weist auf einen sehr hohen Energiebedarf hin, wie beispielsweise auf der südlichen, bergauf führenden Autobahnspur der A9 im vergrößerten Bereich. Auf der nördlichen, bergab führenden Autobahnspur weist die dunkelblaue Farbe hingegen auf hohes Rekuperationspotenzial hin. Damit fasst dieser Energie-Kartenlayer zusammen, was die Planungsbasis für jegliche energetisch planende Anwendung ist, wie etwa die folgend beschriebene Reichweitenberechnung oder das Routing für batterieelektrische Fahrzeuge.

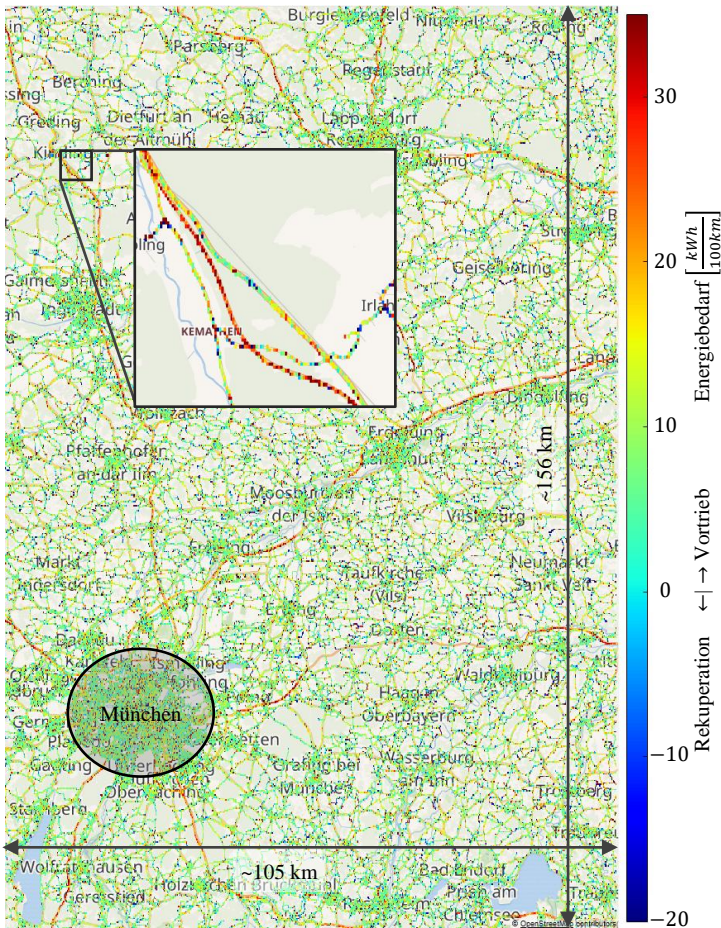


Abb. 8.1: Energie-Kartenlayer (Karte: ©OpenStreetMap contributors)

8.2 Reichweitenberechnung

Während der Fahrt mit einem Elektroauto ist es für den Fahrer wichtig, dass er präzise und zuverlässig weiß, ob er sein Ziel erreichen kann. Dabei unterstützt eine Reichweitenprognose. Diese basiert auf dem aktuell verbleibenden nutzbaren elektrischen Energieinhalt $E_{HVB,ver} [J]$ in der HVB und dem erwarteten

prognostizierten Energiebedarf $\hat{E}_{HVB,pro}$ entsprechend (8.1). Dabei hat in der Genauigkeitsbewertung der Reichweitenprognose der am Ende der Route in der HVB verbleibende Energieinhalt $E_{HVB,ver}[z]$, welcher erst in nächsten unbekanntem Fahrten verbraucht wird, und die damit verbleibende Reichweite $[z]$ Einfluss auf den relativen Fehler. So resultiert die gleiche absolute Reichweitenabweichung bei geringem Energieinhalt $E_{HVB,ver}[z]$ bzw. Reichweite $[z]$ am Ende der Route in einem größeren relativen Fehler als bei großem verbleibendem Energieinhalt. Es ist also über eine Normierung auf eine Streckenreichweite, entsprechend (8.1), zu vermeiden, dass der Restenergieinhalt Einfluss auf den relativen Fehler hat. Für die Berechnung der Streckenreichweite reduziert (8.1) den aktuell verbleibenden Energieinhalt der HVB $E_{HVB,ver}[j]$ für die Bewertung künstlich um den am Ziel der Fahrt aufgezeichneten Wert $E_{HVB,ver}[z]$. Beide vom Fahrzeugbus entlang der Fahrten aus 4.4.4 aufgezeichneten Werte basieren auf der im Fahrzeug verwendeten SOC-Schätzung. Diesem verbleibenden Energieinhalt stellt die Berechnung der Streckenreichweite (8.1) den prognostizierten Energiebedarf $E_{HVB,pro}$ über der verbleibenden Strecke s_{ver} vom aktuellen Streckenabschnitt j bis zum Ziel z gegenüber. Die damit berechnete Streckenreichweite am aktuellen Streckenabschnitt j können (4.9) und (4.10) über die ganze Fahrt bewerten. Dazu ist die von einem Streckenabschnitt bis zum Fahrtende verbleibende Strecke s_{ver} als Sollgröße verwendbar, entsprechend der Normierung der verbleibenden Energie in der HVB bzw. der Streckenreichweite auf null zum Fahrtende.

Reichweite $[j] = \text{Streckenreichweite}[j] + \text{Reichweite}[z]$,

$$\text{wobei: Streckenreichweite}[j] = \frac{E_{HVB,ver}[j] - E_{HVB,ver}[z]}{\frac{E_{HVB,pro}[j]}{s_{ver}[j]}} \quad (8.1)$$

Der beschriebenen Bewertungsmethodik folgend zeigt Abb. 8.2 das Ergebnis, berechnet mit den Energiebedarfsprognosemodellen aus 7.1. Diese Auswertung umfasst alle 83 Fahrten mit verfügbarem RTTI. Dabei ist die Auswertung auf diejenigen Fahrten mit dem BMW i3 eingeschränkt, welche ohne aktiven verbrennungsmotorisch betriebenen Generator erfolgten. Das soll einen zusätzlichen Einfluss bei der Berechnung der verfügbaren elektrischen Energie in der Auswertung vermeiden. Dies ist wichtig, denn in der Bewertung bezüg-

lich Reichweite bringt die SOC-Schätzung des Fahrzeugs Fehler zusätzlich zu den Fehlern der Energiebedarfsprognose ein. Diese Fehler analysiert z. B. [62]. Außerdem ist bei der Interpretation zu beachten, dass ein Modell mit zu niedriger Energiebedarfsprognose zu überhöhten Reichweitenwerten führt. Das resultiert in der relativen Bewertung MEDPE in einer Vorzeichenumkehr zwischen Abb. 8.2 (oben) und Abb. 7.3 (oben).

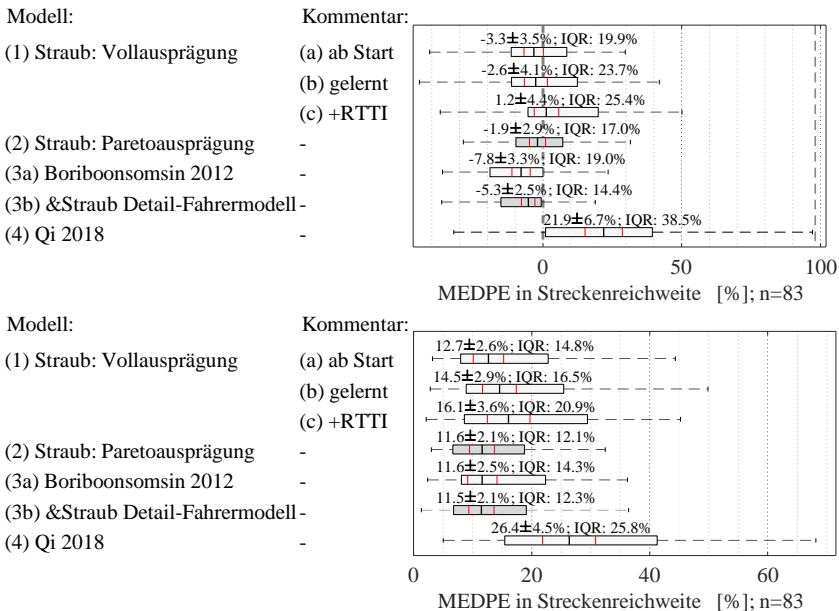


Abb. 8.2: MEDPE (oben) und MEDAPE (unten) der Reichweitenberechnung mit verschiedenen Energieprognosemodellen

Die MEDPE-Bewertung in Abb. 8.2 (oben) zeigt, dass nur die Medianwerte der Voll- (1a-c) und Paretoausprägung (2) nicht signifikant von null abweichen. Dabei zeigt die Auswertung im Vergleich zu denen auf Energiebedarfsprognoseebene eine tendenzielle Verschiebung in Richtung zu konservativen Prognosen. Dieser über alle Modelle hinweg beobachtbare Effekt kann der zusätzliche Einfluss der SOC-Schätzung des Fahrzeugs erklären. Damit schneidet die be-

reits konservative Energiebedarfsprognose (3) nach Boriboonsomsin [80] in der Reichweitenauswertung schlechter im MEDPE-Median ab. Zudem zeigt sich, dass dieser Einfluss die Streuung über die Modelle hinweg verschieden beeinflusst. Mit einer nahezu doppelt so großen IQR-Streuung ist der Effekt für das Modell (4) nach Qi [1] am größten. Durch diese große Streuung und den größten Fehler im MEDPE-Median, resultiert für dieses Modell in Abb. 8.2 (unten) auch der größte MEDAPE-Medianwert. Für diese Kennzahl schneiden die Paretoausprägung (2) und das Modell (3a) nach Boriboonsomsin [80] gerade in Kombination mit dem Detail-Fahrermodell (3b) am besten ab, wenn auch nicht signifikant. Wobei sich hier der Fehler der SOC-Schätzung und Energiebedarfsprognosemodelles überlagern. Im Gegensatz dazu lässt sich für die Vollausrprägung (1) beobachten, dass sich hier eher Fehler überlagern und nicht ausgleichen, was tendenziell schlechtere MEDAPE-Medianwerte zeigen. Damit ist die Paretoausprägung (2) hier am besten geeignet für die Reichweitenprognose, da diese nicht im MEDPE systematisch signifikant abweicht, den zweit-geringsten beobachtete MEDAPE-Medianwert und die geringste Streuung im MEDAPE in dieser Stichprobe aufweist. Insgesamt kann dem Fahrer eines Elektroautos also nur ein abgestimmtes Zusammenspiel von SOC-Schätzung und Energiebedarfsprognose eine präzise Reichweitenprognose bereitstellen.

8.3 Routingfunktion für batterieelektrische Fahrzeuge

Die Information, ob der Fahrer während der Fahrt laden muss, erhält er im Elektroauto über die Reichweite. Wie er jedoch bei Fahrten mit mindestens einem Ladestopp möglichst schnell das Ziel erreicht, ist eine komplexere Aufgabenstellung. Bei einer zeitlich optimalen Fahrtrplanung mit Ladestopps sind fahrzeugspezifische Eigenschaften entscheidend. Neben einer geeigneten Planung der Ladestopps ist auch die gefahrene Geschwindigkeit ein relevanter Freiheitsgrad, um die Ankunft am Ziel zu beeinflussen. Denn mit einer entsprechend angepassten Geschwindigkeit, kann ein Optimierungsalgorithmus Ladestopps entlang der Route mit mehr Freiraum wählen. So kann der Fahrer z. B. eine Ladesäule mit höherer Leistung erreichen oder einen Umweg für

einen kurzen Ladestopps knapp vor dem Ziel vermeiden. Um all diese Einflüsse in einer zeitoptimierten Route zu berücksichtigen, ist eine Kombination der Energiebedarfsprognose mit einem Ladedauermodell in einer Routenberechnung notwendig. Dazu zeigt [131] einen Ansatz im Rahmen dieser Arbeit. Dieser nutzt die Flottendaten aus 6.1.1 mit zwei verschiedenen Energiebedarfsprognosemodellen. Dabei optimiert die Anwendung der Energiebedarfsprognose Geschwindigkeitsvorschläge entlang der Beispielroute München-Verona, was dieses Kapitel mit den Erkenntnissen daraus zusammenfasst. [131]

Die Berechnung der zeitlich optimalen Fahr- und Ladestrategie nutzt in [131] als Eingangsmodelle die flottendatenbasierte Fahrprofil- und Energiebedarfsprognose sowie ein Ladedauermodell. Dazu veranschaulicht Abb. 8.3 deren Zusammenspiel. Zunächst erfolgt für den definierten Fahrauftrag die Berechnung der Route über eine Anfrage an die Programmierschnittstelle eines Routing-Dienstleisters [144]. Diese Route gleicht ein Map-Matching basierend auf einem Hidden-Markov-Modell mit der für die Flottendaten aus 6.1.1 verwendeten Karte ab [128]. Aus den Flottendaten ermittelt die Fahrprofilprognose entsprechend 6.1.2 nicht nur die Median-FPKA sondern auch als Optimierungsspielraum obere v_O und untere v_U Geschwindigkeitsgrenzen je Streckenabschnitt j . Pro Streckenabschnitt j berechnen zwei Energiebedarfsprognosemodelle für mehrere Inkremente zwischen den Geschwindigkeitsgrenzen den Fahrzeugenergiebedarf E . Das Erste ist ein Kennfeldmodell, welches mit einem Polynom sechsten Grades über konstant gefahrene Geschwindigkeit und Steigung eines Streckenabschnitts den Energiebedarf berechnet. Das Zweite ist ein physikalisches Fahrzeugmodell ähnlich dem Basismodell aus 5.1 mit fix angenommenen Nebenverbrauchern, welches für vom Flotten-Median abweichende Geschwindigkeiten den Energiebedarf analog (6.15) und (6.16) anpasst. Die Energiebedarfe und Geschwindigkeitsgrenzen stellen die Modelle entsprechend einer größeren Aggregation der Streckenabschnitte der Optimierung zur Verfügung. Das lässt bei überschaubarem Genauigkeitsverlust deutlich kürzere Optimierungsrechenzeiten zu. Als letzte Eingangsinformation stellt das Ladedauermodell über ein Polynom vierten Grades Ladedauern t_{Laden} abhängig vom Ladehub ΔSOC_{Laden} zur Verfügung. Die Optimierung mittels Dynamischer Programmierung nach [145] berechnet aus den Eingangsinformationen die zeitoptimale Wahl von Geschwindigkeit v je

Streckenabschnitt j und an welchen Ladesäulen ein Ladehub ΔSOC_{Laden} zu realisieren ist. [131]

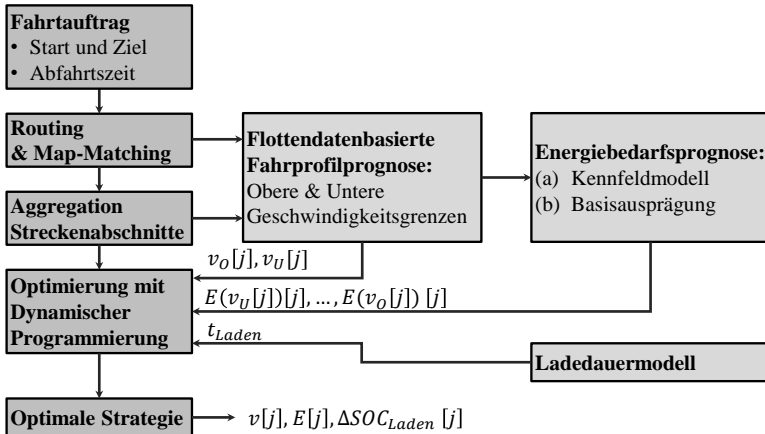


Abb. 8.3: Struktur der zeitoptimalen Fahr- & Ladestrategieermittlung [nach 131, S. 136]

In einer beispielhaften Fallstudie ermittelt die Dynamische Programmierung in [131] das zeitoptimale Vorgehen zur Fahrt der Route von München nach Verona. Entlang der 425 km langen Strecke stehen laut [146] 39 Ladepunkte mit 50 bis 120 kW Leistung zur Verfügung. Zudem enthalten die Flottendaten entsprechend 4.4.4 insgesamt $6,0 \cdot 10^5$ km auf dieser Route aufgezeichnete Fahrprofildaten. Für die Fallstudie anhand dieser Route zeigt Tab. 8.1 den entsprechend der Rechenzeit des Optimierers für die Anwendung relevanten Ausschnitt mit Streckenabschnitten von maximal 10 000 m Länge. Für die ebenfalls berechnete 50 m Auflösung dauert die Berechnung über 80-mal länger. Zudem sei hier nur die moderatere Variante zur Bestimmung der Geschwindigkeitsgrenzen gezeigt, die das 30 % und 70 % Flottenperzentil heranzieht. Dabei zeigt die Fallstudie, dass eine zuverlässigere Fahrstrategie mit der präziseren physikalischen Energiebedarfsprognose möglich ist, da diese Beschleunigungen berücksichtigt. Durch diese ergibt sich ein Mehrverbrauch von 2,3 %, wodurch der Optimierer die mittlere Geschwindigkeit absenken muss. Daraus resultiert eine 9,2 Minuten längere Gesamtreisezeit. In der Anwendung

ist das Optimierungsergebnis, das auf der präziseren Energiebedarfsprognose in der Basisausprägung basiert, robuster bezüglich der Ladeorte bei gleichen gewählten Orten mit beiden energetischen Modellen. Zusammengefasst kann diese flottendatengestützte Optimierung dem Fahrer eines Elektroautos die Entscheidung über die Fahr- & Ladestrategie abnehmen und eine zuverlässige und schnelle Ankunft am Ziel ermöglichen. [131]

Tab. 8.1: Optimierungsergebnisse mit kennfeldbasierter und Abweichungen dazu mit der physikalischen Energiebedarfsprognose [aus 131, S. 143]

Geschwindigkeitsintervall Diskretisierungslänge Segmentierung Energiebedarfsprognosemodell	[30 %; 70 %] 10 000 m	
	Kennfeld	Physikalisch
Anzahl Segmente	106	
Rechenzeit Optimierer [s]	122,4	
Mittlere obere Geschwindigkeitsgrenze [km/h]	114,4	
Mittlere untere Geschwindigkeitsgrenze [km/h]	101,4	
Mittlere optimierte Geschwindigkeit [km/h]	108,8	-2,9
Anzahl Ladevents	1	gleich
SOC nach Laden [%]	100	gleich
Geladener SOC [%]	51,0	+3,0
Gesamtreisezeit [min]	298,4	+9,2

9 Zusammenfassung und Ausblick

Ziel dieser Arbeit ist es, den Energiebedarf eines Elektrofahrzeuges entlang bekannter Routen präzise vorherzusagen. Der Nutzen dieser Prognose ist, dass energetisch planende Anwendungen und Optimierungen im Alltag den Umgang mit elektrifizierten Fahrzeugen einfacher und effizienter machen können. So kann eine präzise und zuverlässige Reichweitenanzeige Reichweitenängste reduzieren. Diese, so manchen potenziellen Käufer hemmenden, Ängste entstehen durch lange Ladezeiten und eine eingeschränkte Schnellladeinfrastruktur. Die Entscheidung, wie der Fahrer die Ladeinfrastruktur auf Langstreckenfahrten für eine kurze Gesamtreisezeit nutzen sollte, kann eine Optimierung der Geschwindigkeits- und Ladestrategie abnehmen. All diese Anwendungen benötigen präzise und zuverlässige Information zum Energiebedarf auf der vorausliegenden Strecke.

Verschieden aufwendige und präzise Algorithmen in der Literatur berechnen den Energiebedarf. Bisher finden sich dabei einfache Modelle, die geschwindigkeits- und steigungsabhängige Kennfelder nutzen, aber auch aufwendigere Modelle, die jeden möglichen Routenabschnitt aus Flottendaten energetisch charakterisieren und etwa mit Machine Learning den Energieverbrauch ableiten. Dabei findet sich in der Literaturrecherche kein für unterschiedliche Fahrzeugtypen verwendbarer Ansatz, der basierend auf Flottendaten die relevanten Einflüsse physikalisch nachvollziehbar, separat beschreibt und dabei explizit Beschleunigungen entsprechend dem Energiefluss modelliert. Zudem findet sich kein auf dem gleichen Datensatz basierender Vergleich zu anderen Methoden, der zur Bewertung des präsentierten Ansatzes dient. Dem gegenüber zeigte diese Arbeit, wie genau eine flottendatenbasierte physikalische Energiebedarfsprognose für Routen ist, die separate Teilmodelle für die relevanten Einflüsse nutzt und auf andere Fahrzeuge übertragbar ist. Darüber hinaus erfolgt ein Vergleich mit vorhandenen Modellen innerhalb einer Analyse bezüglich Genauigkeit und Rechenaufwand.

Zunächst identifiziert eine Sensitivitätsanalyse alle für den Energiebedarf eines Elektrofahrzeuges relevanten Einflüsse. Dazu zählen Fahrzeugeigenschaften, Wetter und Fahrprofil in Abhängigkeit von der Strecke, Verkehr und insbesondere auch das Fahrerverhalten. Diese Erkenntnisse fließen in eine als Vollausprägung bezeichnete, möglichst genaue Energiebedarfsprognose ein. Die Fahrzeugeigenschaften ermittelt darin eine bereits bekannte Fahrwiderstandsschätzung. Dabei erfolgt in der Vollausprägung der Prognose, basierend auf einer Wetterprognose, eine Anpassung der Fahrwiderstände und des Verbrauchs der Fahrzeugtemperierung. Die außerdem notwendige Fahrprofilprognose nutzt über 30 Millionen Kilometer an Flottendaten, um den Streckeneinfluss orts- und zeitspezifisch auszuweisen. Dabei beschreiben fünf neu hergeleitete energetische Fahrprofilkartenattribute mit expliziter Unterscheidung der Energieflussrichtungen jeden Streckenabschnitt. Darauf aufbauend prognostiziert ein Fahrermodell die Fahrprofilinformation unter Berücksichtigung von Echtzeitverkehrsinformation für die Energiebedarfsprognose. Neben der bis hier beschriebenen Vollausprägung nutzt eine durch ein Regressions-Fahrzeugmodell weniger einflusspezifische, aber dafür weniger aufwendige Paretoausprägung mit einem vereinfachten Fahrermodell in gleicher Weise die Flottendaten. Die Genauigkeit und den Rechenaufwand dieser Ausprägungen sowie die von zwei bekannten Modellen analysiert eine Bewertung basierend auf über 12 000 km gesammelten Validierungsdaten.

Dabei zeigen die Ergebnisse, dass das rechenaufwendigste Energiebedarfsprognosemodell in Vollausprägung mit einem MEDAPE-Medianwert von $12,5 \pm 2,6$ % ein Zehntel genauer ist als die ein Drittel schneller rechnende Paretoausprägung, wenn auch nicht signifikant. Die auch ähnlich schnelle rechnenden Literaturmodelle von Boriboonsomsin [80] und Qi [1] sind in der betrachteten Stichprobe hingegen fast ein Fünftel bzw. über zwei Drittel ungenauer. Nur die Kombination von Boriboonsomsin's Antriebsmodell mit dem Detail-Fahrermodell aus dieser Arbeit erlaubt ähnlich gute Ergebnisse, wie die Paretoausprägung. Basierend auf diesen Erkenntnissen zu Energiebedarfsprognoseansätzen zeigt diese Arbeit abschließend deren Anwendung in einer Reichweitenprognose, sowie einer zeitlichen Optimierung von Routen mit Ladestops. Die Genauigkeitsbewertung der Reichweitenprognose zeigt, dass neben der Präzision der Energiebedarfsprognose auch das Zusammenspiel mit

der Schätzung der verfügbaren Energie in der Hochvoltbatterie entscheidend ist. Das funktioniert am besten mit der Paretoausprägung. Darüber hinaus zeigt sich für die zeitliche Routenoptimierung mit den Stellhebeln der Ladestoppplanung und der Geschwindigkeit, dass die physikalische Energiebedarfsprognose die Strategieberechnung robuster macht. Dazu trägt einerseits die flottendatenbasierte orts- und zeitspezifische Festlegung der Bandbreite der Geschwindigkeitsoptimierung bei, andererseits aber auch die präzise Modellierung von Beschleunigungen in der Energiebedarfsprognose. Eine zukünftige Routenplanung für hochautomatisiert fahrende Elektrofahrzeuge könnte diese flottendatengestützte Planung nutzen. Des Weiteren kann solch eine Planung sowie die zu Grunde liegende energetische, orts aufgelöste Flotteninformation die Basis für eine zielgerichtete Ladeinfrastrukturplanung des dahinter liegenden Energieversorgungsnetzes sein. Andererseits kann die Energiebedarfsprognose auf Antriebsebene bei mehr als einer Energiespeicherart die Grundlage für deren effiziente und bauteilschonende Betriebsstrategie sein. Dabei sind Energiespeicher(-medien) wie Kraftstoff, Wasserstoff, Erdgas und natürlich Batteriespeicher denkbar.

Veröffentlichungen

Hier eine Liste meiner Veröffentlichungen als Autor oder Co-Autor aus meiner Arbeit an dieser Dissertation am Karlsruher Institut für Technologie. Die vollständige Liste an Veröffentlichungen ist auch auf researchgate zu finden (https://www.researchgate.net/profile/Tobias_Straub4).

Peer reviewed Journal Artikel:

- [125] STRAUB, T.; FREY, M.; GAUTERIN, F.: *Learning From the Fleet: Map Attributes for Energetic Representation of Driving Profiles*. In: *IEEE Transactions on Intelligent Transportation Systems* 23 (2022), Nr. 1, S. 471–482.
DOI: www.doi.org/10.1109/TITS.2020.3011976
- [126] STRAUB, T.; NAGY, M.; SIDOROV, M.; TONETTO, L.; FREY, M.; GAUTERIN, F.: *Energetic Map Data Imputation: A Machine Learning Approach*. In: *Energies* 13 (2020), Nr. 4, S. 1–23.
DOI: www.doi.org/10.3390/en13040982 (Entstanden im Rahmen von [147, betreute Abschlussarbeit])
- [131] CUSSIGH, M.; STRAUB, T.; FREY, M.; HAMACHER, T.; GAUTERIN, F.: *An All-Electric Alpine Crossing: Time-Optimal Strategy Calculation via Fleet-Based Vehicle Data*. In: *IEEE Open Journal of Intelligent Transportation Systems* 1 (2020), Nr. 1, S. 134–146.
DOI: www.doi.org/10.1109/OJITS.2020.3019599

Peer reviewed Konferenzartikel:

- [148] CUSSIGH, M.; LÖCHEL, C.; STRAUB, T.; HAMACHER, T.: *Assessing Time-Optimal Journeys: Combined Routing, Charging and Velocity Strategies for Electric Vehicles*. In: *IEEE Forum on Integrated and Sustainable Transportation System*. Delft, 2020, S. 51–57.
DOI: www.doi.org/10.1109/FISTS46898.2020.9264845

Betreute Abschlussarbeiten

Hier folgt eine Liste der von mir betreuten Abschlussarbeiten aus meiner Zeit der Arbeit an dieser Dissertation am Karlsruher Institut für Technologie. Aufgelistet sind die Abschlussarbeiten, deren Inhalt mit in diese Dissertation eingeflossen ist. Der erste Literaturverweis ist jeweils mit dem Hinweis „betreute Abschlussarbeit“ versehen.

Bachelor Thesis:

- [141] BÜCHNER, M.: *Clustering of Probability Distributions Using Self-Organizing Maps for Fleet-Based Route Energy Prediction*. Bachelor Thesis. Karlsruhe: Karlsruher Institut für Technologie (KIT), 2018 (18-F-0081)

Master Thesis:

- [129] TRASKOVSKIS, E.: *Estimation of power train efficiency for electric vehicles during travel*. Master Thesis. Kleve: Hochschule Rhein-Waal, 2018
- [140] KIENER, M.: *Clustering of Fleet Data for Energy Prediction*. Master Thesis. München: Technische Universität München, 2019
- [120] NEUMAIER, G.: *Integration von Wetterdaten in die Reichweitenprognose von batterieelektrischen Fahrzeugen*. Master Thesis. Karlsruhe: Karlsruher Institut für Technologie (KIT), 2019 (19-F-0018)
- [147] NAGY, M.: *Energetic Map Data Imputation: A Machine Learning Approach*. Master Thesis. München: Technische Universität München, 2020

Literaturverzeichnis

- [1] QI, X.; WU, G.; BORIBOONSOMSIN, K.; BARTH, M. J.: *Data-driven decomposition analysis and estimation of link-level electric vehicle energy consumption under real-world traffic conditions*. In: *Transportation Research Part D: Transport and Environment* 64 (2018), S. 36–52.
DOI: www.doi.org/10.1016/j.trd.2017.08.008
- [2] EUROPEAN COMMISSION: *2030 climate & energy framework - Climate Action - European Commission*. Zuletzt geprüft: 22.12.20.
URL: https://unfccc.int/sites/default/files/english_paris_agreement.pdf
- [3] EUROPEAN COMMISSION: *State of the Union: Commission raises climate ambition*. Zuletzt geprüft: 06.04.21. URL: https://ec.europa.eu/commission/presscorner/detail/en/IP_20_1599
- [4] UNITED NATIONS: *Paris Agreement*. Zuletzt geprüft: 06.04.21.
URL: https://unfccc.int/sites/default/files/english_paris_agreement.pdf
- [5] KRAFTFAHRT-BUNDESAMT: *Fahrzeuge - Neuzulassungen von Pkw in den Jahren 2010 bis 2019 nach ausgewählten Kraftstoffarten*. Zuletzt geprüft: 22.12.20. URL: https://www.kba.de/DE/Statistik/Fahrzeuge/Neuzulassungen/Umwelt/fz_n_umwelt_archiv/2019/n_umwelt_z.html?nn=2601598
- [6] INTERNATIONAL ENERGY AGENCY: *Global EV Outlook*. 2020. Zuletzt geprüft: 22.12.20. URL: http://www.avere-france.org/Uploads/Documents/1592385579525e5999e87f780c79b80d5eb7f996c6-Global_EV_Outlook_2020.pdf
- [7] THORGEIRSSON, A. T.; SCHEUBNER, S.; FUNFGELD, S.; GAUTERIN, F.: *An Investigation Into Key Influence Factors for the Everyday Usability of Electric Vehicles*. In: *IEEE Open Journal of Vehicular Technology* 1 (2020), S. 348–361. DOI: www.doi.org/10.1109/OJVT.2020.3031699
- [8] EISEL, M.; NASTJUK, I.; KOLBE, L. M.: *Understanding the influence of in-vehicle information systems on range stress – Insights from an*

- electric vehicle field experiment*. In: *Transportation Research Part F: Traffic Psychology and Behaviour* 43 (2016), S. 199–211.
DOI: www.doi.org/10.1016/j.trf.2016.10.015
- [9] DUDEN: *Reichweitenangst*. Zuletzt geprüft: 07.02.21.
URL: <https://www.duden.de/rechtschreibung/Reichweitenangst>
- [10] FRANKE, T.; NEUMANN, I.; BÜHLER, F.; COCRON, P.; KREMS, J. F.: *Experiencing Range in an Electric Vehicle: Understanding Psychological Barriers, EXPERIENCING RANGE*. In: *Applied Psychology* 61 (2012), Nr. 3, S. 368–391. DOI: www.doi.org/10.1111/j.1464-0597.2011.00474.x
- [11] DUFFNER, F.; WENTKER, M.; GREENWOOD, M.; LEKER, J.: *Battery cost modeling: A review and directions for future research*. In: *Renewable and Sustainable Energy Reviews* 127 (2020), S. 1–14.
DOI: www.doi.org/10.1016/j.rser.2020.109872
- [12] CUSSIGH, M.; HAMACHER, T.: *Optimal Charging and Driving Strategies for Battery Electric Vehicles on Long Distance Trips: a Dynamic Programming Approach*. In: *2019 IEEE Intelligent Vehicles Symposium (IV)*: IEEE. Paris, 2019, S. 2093–2098.
DOI: www.doi.org/10.1109/IVS.2019.8813822
- [13] GUZZELLA, L.; SCIARRETTA, A.: *Vehicle propulsion systems: Introduction to modeling and optimization*. 3. ed. Heidelberg: Springer, 2013 (1). DOI: www.doi.org/10.1007/978-3-642-35913-2
- [14] ERSOY, M.; GIES, S.: *Fahrwerkhandbuch: Grundlagen - Fahrdynamik - Fahrverhalten - Komponenten - Elektronische Systeme - Fahrerassistenz - Autonomes Fahren - Perspektiven // Grundlagen - Fahrdynamik - Fahrverhalten - Komponenten - elektronische Systeme - Fahrerassistenz - autonomes Fahren - Perspektiven*. 5. Auflage. Wiesbaden: Springer Fachmedien Wiesbaden; Springer Vieweg, 2017 (ATZ/MTZ-Fachbuch). DOI: www.doi.org/10.1007/978-3-658-15468-4
- [15] HAKEN, K.-L.: *Grundlagen der Kraftfahrzeugtechnik*. 4., aktualisierte Aufl. München: Hanser, 2015 (Hanser eLibrary).
DOI: www.doi.org/10.3139/9783446441057

- [16] LIEBL, J.; LEDERER, M.; ROHDE-BRANDENBURGER, K.; BIERMANN, J.-W.; ROTH, M.; SCHÄFER, H.: *Energiemanagement im Kraftfahrzeug: Optimierung von CO₂-Emissionen und Verbrauch konventioneller und elektrifizierter Automobile*. Wiesbaden: Springer Vieweg, 2014 (ATZ/MTZ-Fachbuch). DOI: www.doi.org/10.1007/978-3-658-04451-0
- [17] RADKE, T.: *Energieoptimale Längsführung von Kraftfahrzeugen durch den Einsatz vorausschauender Fahrstrategien*. Dissertation. Print on demand. Karlsruhe: KIT Scientific Publishing, 2013 (Karlsruher Schriftenreihe Fahrzeugsystemtechnik Band 19). DOI: www.doi.org/10.5445/KSP/1000035819
- [18] MITSCHKE, M.; WALLENTOWITZ, H.: *Dynamik der Kraftfahrzeuge*. 5., überarb. u. erg. Aufl. Wiesbaden: Springer Vieweg, 2014 (VDI-Buch). DOI: www.doi.org/10.1007/978-3-658-05068-9
- [19] PISCHINGER, S.; SEIFFERT, U.: *Vieweg Handbuch Kraftfahrzeugtechnik*. 8., akt. u. erw. Aufl. Wiesbaden: Springer Vieweg, 2016 (ATZ/MTZ-Fachbuch). DOI: www.doi.org/10.1007/978-3-658-09528-4
- [20] SCHÜTZ, T.: *Hucho - Aerodynamik des Automobils: Strömungsmechanik, Wärmetechnik, Fahrdynamik, Komfort*. 6. vollst. überarb. und erw. Aufl. Wiesbaden: Springer Vieweg, 2013 (ATZ/MTZ-Fachbuch). DOI: www.doi.org/10.1007/978-3-8348-2316-8
- [21] LEE, S. J.: *Development and analysis of an air spring model*. In: *International Journal of Automotive Technology* 11 (2010), Nr. 4, S. 471–479. DOI: www.doi.org/10.1007/s12239-010-0058-5
- [22] CLARK, S. K.: *Rolling resistance of pneumatic tires*. In: *Tire Science and Technology* 6 (1978), Nr. 3, S. 163–175
- [23] GREINER, M.; SAUER, R.; GAUTERIN, F.; WIEDEMANN, J.: *Entwicklung einer realitätsnahen Rollwiderstandsmessprozedur basierend auf realen Fahrzyklen bei Elektrofahrzeugen Betriebsparametern auf Basis standardisierter Rollwiderstandsmessungen*. Abschlussbericht. Karlsruhe: Karlsruher Institut für Technologie (KIT), 2016

- [24] ISO 28580:2018-07. 2018. *Passenger car, truck and bus tyre rolling resistance measurement method — Single point test and correlation of measurement results*
- [25] GÜNTER, F.: *Experimentelle Untersuchung der Verlustleistung von Pkw-Reifen*. Dissertation. Karlsruhe: Universität Karlsruhe, 1994
- [26] UNRAU, H.-J.: *Der Einfluss der Fahrbahnoberflächenkrümmung auf den Rollwiderstand, die Cornering Stiffness und die Aligning Stiffness von Pkw-Reifen*. Dissertation. Karlsruhe: KIT Scientific Publishing, 2013 (Karlsruher Schriftenreihe Fahrzeugsystemtechnik 16). DOI: www.doi.org/10.5445/KSP/1000032808
- [27] LAJUNEN, A.; TAMMI, K.: *Energy consumption of electric vehicles in different climate and driving conditions*. In: *EVS30 International Battery, Hybrid and Fuel Cell Electric Vehicle Symposium*. Stuttgart, 2017, S. 1–10. ISBN: 978-1-5108-6370-5
- [28] FREY, M.: *Systematische Untersuchung der Verlustleistung von PKW-Reifen*. Diplomarbeit. Karlsruhe: Universität Karlsruhe, 1993
- [29] FREY, M.; GNADLER, R.; GÜNTER, F.: *Untersuchung der Verlustleistung an PKW Reifen*. In: *VDI-Berichte 1224* (1995), S. 101–128
- [30] VINCKEN, D.: *Der Reifen: Rollwiderstand und Kraftstoffersparnis*. Dt. Erstauf. Clermont-Ferrand: Societé de Technologie Michelin, 2005. ISBN: 2-06-711658-4
- [31] ZHOU, M.; JIN, H.; WANG, W.: *A review of vehicle fuel consumption models to evaluate eco-driving and eco-routing*. In: *Transportation Research Part D: Transport and Environment* 49 (2016), S. 203–218. DOI: www.doi.org/10.1016/j.trd.2016.09.008
- [32] GREINER, M.: *Verfahren zur Prädiktion des Rollwiderstands bei variablen Betriebsparametern auf Basis standardisierter Rollwiderstandsmessungen*. Dissertation. Karlsruhe: KIT Scientific Publishing, 2019 (Karlsruher Schriftenreihe Fahrzeugsystemtechnik Band 71). DOI: www.doi.org/10.5445/KSP/1000091012

- [33] CLARK, S. K.; DODGE, R. N.: *A handbook for the rolling resistance of pneumatic tires*. Ann Arbor: University of Michigan, 1979. 27.01.2023. URL: <https://deepblue.lib.umich.edu/bitstream/handle/2027.42/4274/bac0913.0001.001.pdf>
- [34] GEHMAN, S. D.; LUDEMA, K. C.; BACKER, S.; TAKEYAMA, T.; MATSUI, J.; CLARK, S. K.; GOUGH, V. E.; WALTER, J. D.; SCHALLAMACH, A.; VAN ELDIK THIEME, H. C. A.; PACEJKA, H. B.: *Mechanics of pneumatic tires*. Gaithersburg, MD: National Bureau of Standards, 1971. DOI: www.doi.org/10.6028/NBS.MONO.122
- [35] RHODE, S.: *Robust and regularized algorithms for vehicle tractive force prediction and mass estimation*. Dissertation. Karlsruhe: KIT Scientific Publishing, 2016 (Karlsruher Schriftenreihe Fahrzeugsystemtechnik Band 62). DOI: www.doi.org/10.5445/KSP/1000083492
- [36] KISS, P.; JÁNOSI, I. M.: *Comprehensive empirical analysis of ERA-40 surface wind speed distribution over Europe*. In: *Energy Conversion and Management* 49 (2008), Nr. 8, S. 2142–2151. DOI: www.doi.org/10.1016/j.enconman.2008.02.003
- [37] PRYOR, S. C.; BARTHELMIE, R. J.; YOUNG, D. T.; TAKLE, E. S.; AR- RITT, R. W.; FLORY, D.; GUTOWSKI, W. J.; NUNES, A.; ROADS, J.: *Wind speed trends over the contiguous United States*. In: *Journal of Geophysical Research* 114 (2009), D14, S. 275. DOI: www.doi.org/10.1029/2008JD011416
- [38] PICARD, A.; DAVIS, R. S.; GLÄSER, M.; FUJII, K.: *Revised formula for the density of moist air (CIPM-2007)*. In: *Metrologia* 45 (2008), Nr. 2, S. 149–155. DOI: www.doi.org/10.1088/0026-1394/45/2/004
- [39] LOOMAN, J.: *Zahnradgetriebe: Grundlagen, Konstruktionen, Anwendungen in Fahrzeugen*. 3. neubearb. u. erw. Aufl. 1996, Nachdr. in veränderter Ausstattung. Berlin, Heidelberg: Springer, 2009 (Klassiker der Technik). DOI: www.doi.org/10.1007/978-3-540-89460-5
- [40] WALLENTOWITZ, H.; FREIALDENHOVEN, A.: *Strategien zur Elektrifizierung des Antriebsstranges: Technologien, Märkte und Implikationen*. 2., überarbeitete Auflage. Wiesbaden: Vieweg+Teubner Verlag / Springer

- Fachmedien Wiesbaden GmbH Wiesbaden, 2011 (ATZ/MTZ-Fachbuch). DOI: www.doi.org/10.1007/978-3-8348-9910-1
- [41] NAUNHEIMER, H.; BERTSCHE, B.; LECHNER, G.; RYBORZ, J.: *Fahrzeuggetriebe: Grundlagen, Auswahl, Auslegung und Konstruktion*. 2., bearb. und erw. Aufl. Berlin, Heidelberg: Springer-Verlag, 2007 (VDI-Buch). DOI: www.doi.org/10.1007/978-3-540-30670-2
- [42] REN, Q.; CROLLA, D. A.; MORRIS, A.: *Effect of transmission design on Electric Vehicle (EV) performance*. In: *IEEE Vehicle Power and Propulsion Conference: IEEE*. Dearborn, 2009, S. 1260–1265. DOI: www.doi.org/10.1109/VPPC.2009.5289707
- [43] SPANOUDAKIS, P.; TSOURVELOUDIS, N.; DOITSIDIS, L.; KARAPIDAKIS, E.: *Experimental Research of Transmissions on Electric Vehicles' Energy Consumption*. In: *Energies* 12 (2019), Nr. 3, S. 1–15. DOI: www.doi.org/10.3390/en12030388
- [44] TEIGELKÖTTER, J.: *Energieeffiziente elektrische Antriebe: Grundlagen, Leistungselektronik, Betriebsverhalten und Regelung von Drehstrommotoren*. Wiesbaden: Vieweg+Teubner Verlag; Springer Vieweg, 2013 (Studium). DOI: www.doi.org/10.1007/978-3-8348-2330-4
- [45] UN-NOOR, F.; PADMANABAN, S.; MIHET-POPA, L.; MOLLAH, M.; HOSSAIN, E.: *A Comprehensive Study of Key Electric Vehicle (EV) Components, Technologies, Challenges, Impacts, and Future Direction of Development*. In: *Energies* 10 (2017), Nr. 8, S. 1–84. DOI: www.doi.org/10.3390/en10081217
- [46] LEIDHOLD, R.: *4. Elektrische Maschinen für Elektro- und Hybridfahrzeuge*. In: *MTZ - Motortechnische Zeitschrift* 73 (2012), Nr. 9, S. 692–699. DOI: www.doi.org/10.1007/s35146-012-0460-9
- [47] PYRHONEN, J.; JOKINEN, T.; HRABOVCOVÁ, V.; PYRHÖNEN, J.; HRABOVCOVÁ, V.: *Design of rotating electrical machines*. 1. ed. Chichester: Wiley, 2008. DOI: www.doi.org/10.1002/9780470740095
- [48] FITZGERALD, A. E.; KINGSLEY, C.; UMANS, S. D.: *Electric machinery*. 6. ed., internat. ed. Boston, Mass.: McGraw-Hill, 2003 (McGraw-Hill)

- series in electrical engineering Power and energy). ISBN: 0-07-366009-4
- [49] GOODENOUGH, J. B.: *Summary of losses in magnetic materials*. In: *IEEE Transactions on Magnetics* 38 (2002), Nr. 5, S. 3398–3408. DOI: www.doi.org/10.1109/TMAG.2002.802741
- [50] ZHANG, Y.; PILLAY, P.; IBRAHIM, M.; CHENG, M.-C.: *Magnetic Characteristics and Core Losses in Machine Laminations: High-Frequency Loss Prediction From Low-Frequency Measurements*. In: *IEEE Transactions on Industry Applications* 48 (2012), Nr. 2, S. 623–629. DOI: www.doi.org/10.1109/TIA.2011.2180874
- [51] SAARI, J.: *Thermal analysis of high-speed induction machines*. Zugl.: Dissertation. Espoo: Finnish Academy of Technology, 1998 (Electrical engineering series 90). ISBN: 952-5148-43-2
- [52] LULHE, M. A.; DATE, N. N.: *A technology review paper for drives used in electrical vehicle (EV) & hybrid electrical vehicles (HEV)*. In: *2015 International Conference on Control Instrumentation Communication and Computational Technologies*: IEEE. Kumaracoil, 2015, S. 632–636. DOI: www.doi.org/10.1109/ICCICCT.2015.7475355
- [53] CHEN, X.; HUANG, S.; LI, B.; XIANG, Y.: *Losses and thermal calculation scheme of IGBT and FWD and its application in PWM inverters for electric engineering maintenance rolling stock*. In: *IEEE Transactions on Electrical and Electronic Engineering* 13 (2018), Nr. 12, S. 1822–1828. DOI: www.doi.org/10.1002/tee.22744
- [54] MARTINEZ, B. L. C.; LI, R.; MA, K.; XU, D.: *Hard switching and soft switching inverters efficiency evaluation*. 2008 International Conference on Electrical Machines and Systems. In: *International Conference on Electrical Machines and Systems*: IEEE. Wuhan, 2008, S. 1752–1757. ISBN: 978-1-4244-3826-6
- [55] MASWOOD, A. I.: *A switching loss study in SPWM IGBT inverter*. In: *IEEE 2nd International Power and Energy Conference*: IEEE. Johor Bahru, 2008, S. 609–613. DOI: www.doi.org/10.1109/PECON.2008.4762548

- [56] FEIX, G.; DIECKERHOFF, S.; ALLMELING, J.; SCHONBERGER, J.: *Simple methods to calculate IGBT and diode conduction and switching losses*. In: *13th European Conference on Power Electronics and Applications*: IEEE. Barcelona, 2009, S. 1–8. ISBN: 978-1-4244-4432-8
- [57] SPRAGUE, R.: *An Analysis of Current Battery Technology and Electric Vehicles*. In: *The Journal of Undergraduate Research at the University of Illinois at Chicago* 8 (2017), Nr. 1, S. 70–75.
DOI: www.doi.org/10.5210/jur.v8i1.7544
- [58] KORTHAUER, R.: *Handbuch Lithium-Ionen-Batterien*. Berlin, Heidelberg: Springer Vieweg, 2013. DOI: www.doi.org/10.1007/978-3-642-30653-2
- [59] OMAR, N.; VERBRUGGE, B.; MULDER, G.; VAN DEN BOSSCHE, P.; VAN MIERLO, J.; DAOWD, M.; DHAENS, M.; PAUWELS, S.: *Evaluation of performance characteristics of various lithium-ion batteries for use in BEV application*. In: *IEEE Vehicle Power and Propulsion Conference*: IEEE. Lille, 2010, S. 1–6.
DOI: www.doi.org/10.1109/VPPC.2010.5729083
- [60] BRANDL, M.; GALL, H.; WENGER, M.; LORENTZ, V.; GIEGERICH, M.; BARONTI, F.; FANTECHI, G.; FANUCCI, L.; RONCELLA, R.; SALETTI, R.; SAPONARA, S.; THALER, A.; CIFRAIN, M.; PROCHAZKA, W.: *Batteries and battery management systems for electric vehicles*. In: *Design, Automation & Test in Europe Conference & Exhibition*: IEEE. Dresden, 2012, S. 971–976. DOI: www.doi.org/10.1109/DATE.2012.6176637
- [61] XIONG, R.; CAO, J.; YU, Q.; HE, H.; SUN, F.: *Critical Review on the Battery State of Charge Estimation Methods for Electric Vehicles*. In: *IEEE Access* 6 (2018), S. 1832–1843. DOI: www.doi.org/10.1109/ACCESS.2017.2780258
- [62] SHEHAB EL DIN, M.; HUSSEIN, A. A.; ABDEL-HAFEZ, M. F.: *Improved Battery SOC Estimation Accuracy Using a Modified UKF With an Adaptive Cell Model Under Real EV Operating Conditions*. In: *IEEE Transactions on Transportation Electrification* 4 (2018), Nr. 2, S. 408–417. DOI: www.doi.org/10.1109/TTE.2018.2802043

- [63] ENTHALER, A.; GAUTERIN, F.: *Significance of internal battery resistance on the remaining range estimation of electric vehicles*. In: *International Conference on Connected Vehicles and Expo*: IEEE, Nevada, 2013, S. 94–99.
DOI: www.doi.org/10.1109/ICCVE.2013.6799776
- [64] JAGUEMONT, J.; BOULON, L.; DUBÉ, Y.: *A comprehensive review of lithium-ion batteries used in hybrid and electric vehicles at cold temperatures*. In: *Applied Energy* 164 (2016), S. 99–114.
DOI: www.doi.org/10.1016/j.apenergy.2015.11.034
- [65] PETIT, M.; PRADA, E.; SAUVANT-MOYNOT, V.: *Development of an empirical aging model for Li-ion batteries and application to assess the impact of Vehicle-to-Grid strategies on battery lifetime*. In: *Applied Energy* 172 (2016), S. 398–407. DOI: www.doi.org/10.1016/j.apenergy.2016.03.119
- [66] GRUBWINKLER, S.: *Fahrprofilbasierte Energieverbrauchsprädiktion für vernetzte Elektrofahrzeuge*. Dissertation. München: Verlag Dr. Hut, 2017 (Schriftenreihe des Lehrstuhl für Fahrzeugtechnik der Technischen Universität München). ISBN: 978-3-8439-3189-2
- [67] BASLER, A.: *Eine modulare Funktionsarchitektur zur Umsetzung einer gesamtheitlichen Betriebsstrategie für Elektrofahrzeuge*. Dissertation. Karlsruhe: KIT Scientific Publishing, 2015 (Karlsruher Schriftenreihe Fahrzeugsystemtechnik Band 42).
DOI: www.doi.org/10.5445/KSP/1000048340
- [68] JUNG, M.; KEMLE, A.; STRAUSS, T.; WAWZYNIAK, M.: *Innenraumheizung von Hybrid- und Elektrofahrzeugen*. In: *ATZ-Automobiltechnische Zeitschrift* 113 (2011), Nr. 5, S. 396–402.
DOI: www.doi.org/10.1365/s35148-011-0093-1
- [69] GROBMANN, H.: *Pkw-Klimatisierung: Physikalische Grundlagen und technische Umsetzung*. 2. Aufl. Berlin, Heidelberg: Springer, 2013 (VDI-Buch). DOI: www.doi.org/10.1007/978-3-642-39841-4
- [70] MEGYESI, P.: *Methode zur Einbindung realer Nutzerprofile in die ökologische und ökonomische Bewertung von Fahrzeugkonzepten*.

- Dissertation. Karlsruhe: KIT Scientific Publishing, 2017 (Karlsruher Schriftenreihe Fahrzeugsystemtechnik Band 63).
DOI: www.doi.org/10.5445/KSP/1000083924
- [71] YAVASOGLU, H. A.; TETIK, Y. E.; GOKCE, K.: *Implementation of machine learning based real time range estimation method without destination knowledge for BEVs*. In: *Energy* 172 (2019), S. 1179–1186.
DOI: www.doi.org/10.1016/j.energy.2019.02.032
- [72] SUN, S.; ZHANG, J.; BI, J.; WANG, Y.: *A Machine Learning Method for Predicting Driving Range of Battery Electric Vehicles*. In: *Journal of Advanced Transportation* 2019 (2019), Nr. 6, S. 1–14.
DOI: www.doi.org/10.1155/2019/4109148
- [73] LAMPRECHT, A.: *Energieprädiktion und Reichweitendarstellung durch Navigationsdaten im Kraftfahrzeug*. Dissertation. Chemnitz: Technische Universität Chemnitz, 2016. 27.01.2023. URL: <https://nbn-resolving.org/urn:nbn:de:bsz:ch1-qucosa-213218>
- [74] KLIMESCH, M.; LAMPRECHT, A.; KULNICK, S.: *METHOD FOR DETERMINING THE REMAINING RANGE OF A MOTOR VEHICLE, AND MOTOR VEHICLE*. AUDI AG [DE]; KLIMESCH MICHAEL [DE]; LAMPRECHT ANDREAS [DE]; KULNICK SASCHA [DE]. Anmeldenr. WO2012EP02092 20120516, WO. 24.01.13. WO. Veröffentlichungsnr. WO2013010604 (A2)
- [75] LAMPRECHT, A.: *METHOD FOR DETERMINING AN EXPECTED CONSUMPTION VALUE OF A MOTOR VEHICLE*. AUDI AG [DE]. Anmeldenr. WO2013EP00789 20130314, WO. 31.10.13. WO. Veröffentlichungsnr. WO2013159853 (A1)
- [76] MAUK, T.: *Selbstlernende, zuverlässigkeitsorientierte Prädiktion energetisch relevanter Größen im Kraftfahrzeug*. Dissertation. Renningen: Expert-Verl., 2011 (Schriftenreihe des Instituts für Verbrennungsmotoren und Kraftfahrwesen der Universität Stuttgart 55). ISBN: 3816931235
- [77] SELLSCHOPP, S.: *Predicting an energy consumption of a vehicle*. VOLKSWAGEN AG [DE]; AUDI AG [DE]. Anmeldenr.

- EP20140700583 20140110, Europ. Patent. 02.12.15. Europ. Patent. Veröffentlichungsnr. EP2948357 (A1)
- [78] XIAO, Y.; ZUO, X.; KAKU, I.; ZHOU, S.; PAN, X.: *Development of energy consumption optimization model for the electric vehicle routing problem with time windows*. In: *Journal of Cleaner Production* 225 (2019), S. 647–663. DOI: www.doi.org/10.1016/j.jclepro.2019.03.323
- [79] ZHANG, R.; YAO, E.: *Mesosopic model framework for estimating electric vehicles' energy consumption*. In: *Sustainable Cities and Society* 47 (2019), S. 101478. DOI: www.doi.org/10.1016/j.scs.2019.101478
- [80] BORIBOONSOMSIN, K.; BARTH, M. J.; ZHU, W.; VU, A.: *Eco-Routing Navigation System Based on Multisource Historical and Real-Time Traffic Information*. In: *IEEE Transactions on Intelligent Transportation Systems* 13 (2012), Nr. 4, S. 1694–1704. DOI: www.doi.org/10.1109/TITS.2012.2204051
- [81] CAUWER, C. de; VAN MIERLO, J.; COOSEMANS, T.: *Energy Consumption Prediction for Electric Vehicles Based on Real-World Data*. In: *Energies* 8 (2015), Nr. 12, S. 8573–8593. DOI: www.doi.org/10.3390/en8088573
- [82] CAUWER, C. de; VERBEKE, W.; COOSEMANS, T.; FAID, S.; VAN MIERLO, J.: *A Data-Driven Method for Energy Consumption Prediction and Energy-Efficient Routing of Electric Vehicles in Real-World Conditions*. In: *Energies* 10 (2017), Nr. 12, S. 1–18. DOI: www.doi.org/10.3390/en10050608
- [83] CAUWER, C. de; VERBEKE, W.; VAN MIERLO, J.; COOSEMANS, T.: *A Model for Range Estimation and Energy-Efficient Routing of Electric Vehicles in Real-World Conditions*. In: *IEEE Transactions on Intelligent Transportation Systems* 21 (2020), Nr. 7, S. 2787–2800. DOI: www.doi.org/10.1109/TITS.2019.2918019
- [84] MASIKOS, M.; THEOLOGOU, M.; DEMESTICHAS, K.; ADAMOPOULOU, E.: *Machine-learning methodology for energy efficient routing*. In: *Intelligent Transport Systems* 8 (2014), Nr. 3, S. 255–265. DOI: www.doi.org/10.1049/iet-its.2013.0006

- [85] MASIKOS, M.; DEMESTICHAS, K.; ADAMOPOULOU, E.; THEOLOGOU, M.: *Energy-efficient routing based on vehicular consumption predictions of a mesoscopic learning model*. In: *Applied Soft Computing* 28 (2015), S. 114–124. DOI: www.doi.org/10.1016/j.asoc.2014.11.054
- [86] MASIKOS, M.; DEMESTICHAS, K.; ADAMOPOULOU, E.; THEOLOGOU, M.: *Mesoscopic forecasting of vehicular consumption using neural networks*. In: *Soft Computing* 19 (2015), Nr. 1, S. 145–156. DOI: www.doi.org/10.1007/s00500-014-1238-4
- [87] XU, Y.; WANG, K.: *Research on Estimation Method of Mileage Power Consumption for Electric Vehicles*. In: *Proceedings of the 2018 International Conference on Computer Science, Electronics and Communication Engineering*. Wuhan, 2018, S. 504–508. DOI: www.doi.org/10.2991/csece-18.2018.110
- [88] GRUBWINKLER, S.; BRUNNER, T.; LIENKAMP, M.: *Range Prediction for EVs via Crowd-Sourcing*. In: *IEEE Vehicle Power and Propulsion Conference: IEEE*. Coimbra, 2014, S. 1–6. DOI: www.doi.org/10.1109/VPPC.2014.7007121
- [89] GRUBWINKLER, S.; HIRSCHVOGEL, M.; LIENKAMP, M.: *Driver- and situation-specific impact factors for the energy prediction of EVs based on crowd-sourced speed profiles*. In: *IEEE Intelligent Vehicles Symposium proceedings: IEEE*. Dearborn, 2014, S. 1069–1076. DOI: www.doi.org/10.1109/IVS.2014.6856501
- [90] GRUBWINKLER, S.; KUGLER, M.; LIENKAMP, M.: *A system for cloud-based deviation prediction of propulsion energy consumption for EVs*. In: *IEEE International Conference on Vehicular Electronics and Safety: IEEE*. Dongguan, 2013, S. 99–104. DOI: www.doi.org/10.1109/ICVES.2013.6619611
- [91] GRUBWINKLER, S.; LIENKAMP, M.: *Energy Prediction for EVs Using Support Vector Regression Methods*, Bd. 323. In: *Intelligent Systems '2014*: Springer International Publishing. Warsaw, 2014, S. 769–780. DOI: www.doi.org/10.1007/978-3-319-11310-4_67

- [92] MODI, S.; BHATTACHARYA, J.; BASAK, P.: *Convolutional neural network–bagged decision tree: a hybrid approach to reduce electric vehicle’s driver’s range anxiety by estimating energy consumption in real-time*. In: *Soft Computing* 28 (2020), Nr. 7, S. 1591.
DOI: www.doi.org/10.1007/s00500-020-05310-y
- [93] ZHANG, J.; WANG, Z.; LIU, P.; ZHANG, Z.: *Energy consumption analysis and prediction of electric vehicles based on real-world driving data*. In: *Applied Energy* 275 (2020), S. 1–14.
DOI: www.doi.org/10.1016/j.apenergy.2020.115408
- [94] WANG, J.; BESSELINK, I.; NIJMEIJER, H.: *Electric Vehicle Energy Consumption Modelling and Prediction Based on Road Information*. In: *World Electric Vehicle Journal* 7 (2015), Nr. 3, S. 447–458.
DOI: www.doi.org/10.3390/wevj7030447
- [95] WANG, J.; BESSELINK, I.; NIJMEIJER, H.: *Online Prediction of Battery Electric Vehicle Energy Consumption*. In: *World Electric Vehicle Journal* 8 (2016), Nr. 1, S. 213–224.
DOI: www.doi.org/10.3390/wevj8010213
- [96] WANG, J.; BESSELINK, I.; NIJMEIJER, H.: *Battery electric vehicle energy consumption prediction for a trip based on route information*. In: *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering* 232 (2018), Nr. 11, S. 1528–1542.
DOI: www.doi.org/10.1177/0954407017729938
- [97] BASSO, R.; KULCSÁR, B.; EGARDT, B.; LINDROTH, P.; SANCHEZ-DIAZ, I.: *Energy consumption estimation integrated into the Electric Vehicle Routing Problem*. In: *Transportation Research Part D: Transport and Environment* 69 (2019), S. 141–167.
DOI: www.doi.org/10.1016/j.trd.2019.01.006
- [98] MORLOCK, F.; ROLLE, B.; BAUER, M.; SAWODNY, O.: *Forecasts of Electric Vehicle Energy Consumption Based on Characteristic Speed Profiles and Real-Time Traffic Data*. In: *IEEE Transactions on Vehicular Technology* 69 (2020), Nr. 2, S. 1404–1418.
DOI: www.doi.org/10.1109/TVT.2019.2957536

- [99] SCHEUBNER, S.; THORGEIRSSON, A. T.; VAILLANT, M.; GAUTERIN, F.: *A Stochastic Range Estimation Algorithm for Electric Vehicles Using Traffic Phase Classification*. In: *IEEE Transactions on Vehicular Technology* 68 (2019), Nr. 7, S. 6414–6428.
DOI: www.doi.org/10.1109/TVT.2019.2918544
- [100] YANG, J.-Y.; CHOU, L.-D.; CHANG, Y.-J.: *Electric-Vehicle Navigation System Based on Power Consumption*. In: *IEEE Transactions on Vehicular Technology* 65 (2016), Nr. 8, S. 5930–5943.
DOI: www.doi.org/10.1109/TVT.2015.2477369
- [101] WANG, Y.; JIANG, J.; MU, T.: *Context-Aware and Energy-Driven Route Optimization for Fully Electric Vehicles via Crowdsourcing*. In: *IEEE Transactions on Intelligent Transportation Systems* 14 (2013), Nr. 3, S. 1331–1345. DOI: www.doi.org/10.1109/TITS.2013.2261064
- [102] ZHANG, C.; YANG, F.; KE, X.; LIU, Z.; YUAN, C.: *Predictive modeling of energy consumption and greenhouse gas emissions from autonomous electric vehicle operations*. In: *Applied Energy* 254 (2019), S. 113597.
DOI: www.doi.org/10.1016/j.apenergy.2019.113597
- [103] WANG, J.; ELBERY, A.; RAKHA, H. A.: *A real-time vehicle-specific eco-routing model for on-board navigation applications capturing transient vehicle behavior*. In: *Transportation Research Part C: Emerging Technologies* 104 (2019), S. 1–21.
DOI: www.doi.org/10.1016/j.trc.2019.04.017
- [104] FÜNFGELD, S.: *Vorausschauende Regelung von Fahrzeugsystemen durch stochastische Vorhersage der Fahrzeugdynamik*. Dissertation. Karlsruhe: KIT Scientific Publishing, 2020 (Karlsruher Schriftenreihe Fahrzeugsystemtechnik Band 86).
DOI: www.doi.org/10.5445/KSP/1000125407
- [105] ERICSSON, E.: *Independent driving pattern factors and their influence on fuel-use and exhaust emission factors*. In: *Transportation Research Part D: Transport and Environment* 6 (2001), Nr. 5, S. 325–345.
DOI: [www.doi.org/10.1016/S1361-9209\(01\)00003-7](http://www.doi.org/10.1016/S1361-9209(01)00003-7)

- [106] CHEN, T.; GUESTRIN, C.: *XGBoost*. In: *Proceedings of the Twenty-Fifth International Joint Conference on Artificial Intelligence*: AAAI Press. New York, 2016, S. 785–794.
DOI: www.doi.org/10.1145/2939672.2939785
- [107] ISERMANN, R.; MÜNCHHOF, M.: *Identification of Dynamic Systems: An Introduction with Applications*. Berlin, Heidelberg: Springer; Springer Berlin Heidelberg, 2011 // 2010 (Advanced Textbooks in Control and Signal Processing). DOI: www.doi.org/10.1007/978-3-540-78879-9
- [108] VAN WATERSCHOOT, T.; ROMBOUTS, G.; MOONEN, M.: *Optimally regularized adaptive filtering algorithms for room acoustic signal enhancement*. In: *Signal Processing* 88 (2008), Nr. 3, S. 594–611.
DOI: www.doi.org/10.1016/j.sigpro.2007.09.001
- [109] STENLUND, B.; GUSTAFSSON, F.: *Avoiding windup in recursive parameter estimation*. In: *Preprints of reglermöte 2002* (2002), S. 148–153
- [110] VAHIDI, A.; STEFANOPOULOU, A.; PENG, H.: *Recursive least squares with forgetting for online estimation of vehicle mass and road grade: theory and experiments*. In: *Vehicle System Dynamics* 43 (2005), Nr. 1, S. 31–55. DOI: www.doi.org/10.1080/00423110412331290446
- [111] HUBER, P. J.: *Robust Estimation of a Location Parameter*. In: *The Annals of Mathematical Statistics* 35 (1964), Nr. 1, S. 73–101.
DOI: www.doi.org/10.1214/aoms/1177703732
- [112] RHODE, S.; BLEIMUND, F.; GAUTERIN, F.: *Recursive Generalized Total Least Squares with Noise Covariance Estimation*, Bd. 47. In: *Proceedings of the 19th IFAC world congress*. Cape Town, 2014, S. 4637–4643.
DOI: www.doi.org/10.3182/20140824-6-ZA-1003.01568
- [113] FENG, D.-Z.; ZHENG, W. X.: *Recursive total instrumental-variable algorithm for solving over-determined normal equations and its applications*. In: *Signal Processing* 87 (2007), Nr. 5, S. 918–936.
DOI: www.doi.org/10.1016/j.sigpro.2006.09.015
- [114] SAUTERMEISTER, S.; OTT, F.; VAILLANT, M.; GAUTERIN, F.: *Reducing Range Estimation Uncertainty with a Hybrid Powertrain Model and*

- Online Parameter Estimation*. In: *IEEE 20th International Conference on Intelligent Transportation Systems*: IEEE. Yokohama, 2017, S. 1–6. DOI: www.doi.org/10.1109/ITSC.2017.8317633
- [115] CHOI, K. H.; LEE, J. H.; JUN, J. C.; PARK, J. H.: *SYSTEM AND METHOD FOR ESTIMATING AVAILABLE DRIVING DISTANCE OF ELECTIC VEHICLE*. HYUNDAI MOTOR CO LTD [KR]; IUCF HYU [KR]. Anmeldnr. US201615360086 20161123, US. 08.03.18. US. Veröffentlichungsnr. US2018066958 (A1)
- [116] RUMBOLZ, P.: *Untersuchung der Fahrereinflüsse auf den Energieverbrauch und die Potentiale von verbrauchsreduzierenden Verzögerungsassistenzfunktionen beim PKW*. Dissertation. Renningen: Expert-Verl., 2013 (Schriftenreihe des Instituts für Verbrennungsmotoren und Kraftfahrwesen der Universität Stuttgart 71). ISBN: 9783816932284
- [117] ADERMANN, J.; KREIBICH, J.; LIENKAMP, M.: *Experimental Study of Energy Consumption Variation in Recurring Driving Trips*. In: *JEE (Journal of Electrical Engineering)* 5 (2017), Nr. 5, S. 253–261. DOI: www.doi.org/10.17265/2328-2223/2017.05.004
- [118] ASAMER, J.; GRASER, A.; HEILMANN, B.; RUTHMAIR, M.: *Sensitivity analysis for energy demand estimation of electric vehicles*. In: *Transportation Research Part D: Transport and Environment* 46 (2016), S. 182–199. DOI: www.doi.org/10.1016/j.trd.2016.03.017
- [119] EUROPÄISCHE UNION (EU): *Konsolidierter Text: Verordnung (EU) 2017/1151 der Kommission vom 1. Juni 2017 zur Ergänzung der Verordnung (EG) Nr. 715/2007 des Europäischen Parlaments und des Rates über die Typgenehmigung von Kraftfahrzeugen hinsichtlich der Emissionen von leichten Personenkraftwagen und Nutzfahrzeugen (Euro 5 und Euro 6) und über den Zugang zu Fahrzeugreparatur- und -wartungsinformationen, zur Änderung der Richtlinie 2007/46/EG des Europäischen Parlaments und des Rates, der Verordnung (EG) Nr. 692/2008 der Kommission sowie der Verordnung (EU) Nr. 1230/2012 der Kommission und zur Aufhebung der Verordnung (EG) Nr. 692/2008 der Kommission* (idF v. konsolidierte Fassung; 25. 1. 2020). In: *ABl. (Amtsblatt der Europäischen Union)* (2020), L 175, S. 1–643.

URL: <https://eur-lex.europa.eu/legal-content/DE/TXT/?uri=CELEX%3A32017R1151> . Zuletzt geprüft: 27.01.23

- [120] NEUMAIER, G.: *Integration von Wetterdaten in die Reichweitenprognose von batterieelektrischen Fahrzeugen*. Master Thesis. Karlsruhe: Karlsruher Institut für Technologie (KIT), 2019 (19-F-0018)
- [121] DETHLEFFS GMBH & CO. KG: *Wohnwagen Exklusiv / 740 BFK*. Zuletzt geprüft: 22.12.20. URL: <https://www.dethleffs.de/wohnwagen/bedu-ning-scandinavia/model/740-bfk/>
- [122] NIES, B. J.: *Nutzungsgerechte Dimensionierung des elektrischen Antriebssystems für Plug-In Hybride*. Dissertation. München: Technische Universität München, 2014. 27.01.2023. URL: media-tum.ub.tum.de/node?id=1182610
- [123] ANDRÉ, M.: *The ARTEMIS European driving cycles for measuring car pollutant emissions*. In: *Science of The Total Environment* 334-335 (2004), S. 73–84. DOI: www.doi.org/10.1016/j.scitotenv.2004.04.070
- [124] BAYERISCHE MOTOREN WERKE AG: *MY JOURNEY REAL TIME TRAFFIC INFORMATION*. Zuletzt geprüft: 18.08.20. URL: https://www.bmw-connecteddrive.de/app/index.html?gclid=CjwKCAjw1ej5BRBhEiwAfHyh1F4AJq0j4XTE-HYdfxzREqfsZ5U-OmAWGxKFx3nWg-dHoHHz5XjAJE-BoC2WlQAvD_BwE#/portal/store/Base_RTTIOffer
- [125] STRAUB, T.; FREY, M.; GAUTERIN, F.: *Learning From the Fleet: Map Attributes for Energetic Representation of Driving Profiles*. In: *IEEE Transactions on Intelligent Transportation Systems* 23 (2022), Nr. 1, S. 471–482. DOI: www.doi.org/10.1109/TITS.2020.3011976
- [126] STRAUB, T.; NAGY, M.; SIDOROV, M.; TONETTO, L.; FREY, M.; GAUTERIN, F.: *Energetic Map Data Imputation: A Machine Learning Approach*. In: *Energies* 13 (2020), Nr. 4, S. 1–23. DOI: www.doi.org/10.3390/en13040982

- [127] PARETO, V.: *Cours d'économie politique, Tome II Livre III*. Paris: Imprimeur-Éditeur, 1897
- [128] NEWSON, P.; KRUMM, J.: *Hidden Markov map matching through noise and sparseness*. In: *Proceedings of the 17th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems*: ACM. Seattle, 2009, S. 336–343.
DOI: www.doi.org/10.1145/1653771.1653818
- [129] TRASKOVSKIS, E.: *Estimation of power train efficiency for electric vehicles during travel*. Master Thesis. Kleve: Hochschule Rhein-Waal, 2018
- [130] STATISTISCHES BUNDESAMT: *Mikrozensus - Fragen zur Gesundheit: Körpermaße der Bevölkerung*. 2018. Zuletzt geprüft: 25.08.20.
URL: https://www.destatis.de/DE/Themen/Gesellschaft-Umwelt/Gesundheit/Gesundheitszustand-Relevantes-Verhalten/Publikationen/Downloads-Gesundheitszustand/koerpermasse-5239003179004.pdf?__blob=publicationFile
- [131] CUSSIGH, M.; STRAUB, T.; FREY, M.; HAMACHER, T.; GAUTERIN, F.: *An All-Electric Alpine Crossing: Time-Optimal Strategy Calculation via Fleet-Based Vehicle Data*. In: *IEEE Open Journal of Intelligent Transportation Systems* 1 (2020), Nr. 1, S. 134–146.
DOI: www.doi.org/10.1109/OJITS.2020.3019599
- [132] KÜHLWEIN, J.: *Driving Resistances of Lightduty Vehicles in Europe: Present Situation, Trends, And Scenarios For 2025*. Berlin, 2016. Zuletzt geprüft: 13.02.19. URL: https://www.theicct.org/sites/default/files/publications/ICCT_LDV-Driving-Resistances-EU_121516.pdf
- [133] MEYER, J.; SANGAMESWARAN, S.: *Strecke-bis-Leerzustand-Berechnung auf Routenbasis für ein Fahrzeug*. FORD GLOBAL TECH LLC [US]. Anmeldenr. DE201510113701 20150819, DE. 03.03.16. DE. Veröffentlichungsnr. DE102015113701 (A1)
- [134] SAUER, A.: *Vorausschauende Betriebsstrategie eines seriellen Hybridfahrzeuges durch dynamische Optimierung und Backend-Anbindung*. Dissertation. 1. Auflage. Magdeburg: Verlag Dr. Hut, 2018 (Ingenieurwissenschaften). DOI: www.doi.org/10.17170/kobra-202012182714

- [135] ZHANG, Y.; WANG, W.; KOBAYASHI, Y.; SHIRAI, K.: *Remaining driving range estimation of electric vehicle*. 2012 IEEE International Electric Vehicle Conference. In: *2012 IEEE International Electric Vehicle Conference*: IEEE. Greenville, 2012, S. 1–7.
DOI: www.doi.org/10.1109/IEVC.2012.6183172
- [136] STEPANOW, N. J.: *Über die elektrische Leitfähigkeit der Metallegierungen*. In: *Zeitschrift für anorganische Chemie* 78 (1912), Nr. 1, S. 1–32.
DOI: www.doi.org/10.1002/zaac.19120780102
- [137] APACHE SPARK: *PySpark Documentation*. Zuletzt geprüft: 22.12.20.
URL: <https://spark.apache.org/docs/latest/api/python/index.html>
- [138] PARZEN, E.: *Quantile Probability and Statistical Data Modeling*. In: *Statistical Science* 19 (2004), Nr. 4, S. 652–662.
DOI: www.doi.org/10.1214/088342304000000387
- [139] IFAK; GfK MEDIA AND COMMUNICATION RESEARCH; FORSA MARPLAN: *Verbrauchs- und Medienanalyse - VuMA 2020*. 2019. Zuletzt geprüft: 21.11.20. URL: <https://de.statista.com/statistik/daten/studie/183003/umfrage/pkw---gefahrenere-kilometer-pro-jahr/>
- [140] KIENER, M.: *Clustering of Fleet Data for Energy Prediction*. Master Thesis. München: Technische Universität München, 2019
- [141] BÜCHNER, M.: *Clustering of Probability Distributions Using Self-Organizing Maps for Fleet-Based Route Energy Prediction*. Bachelor Thesis. Karlsruhe: Karlsruher Institut für Technologie (KIT), 2018 (18-F-0081)
- [142] SOMMERFELD, M.: *Wasserstein Distance on Finite Spaces: Statistical Inference and Algorithms*. Dissertation. Göttingen: Georg-August-Universität Göttingen, 2017. DOI: www.doi.org/10.53846/goediss-6631
- [143] ARTHUR, D.; VASSILVITSKII, S.: *K-Means++: The Advantages of Careful Seeding*. In: *Proceedings of the Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms*: Society for Industrial and Applied Mathematics. New Orleans Louisiana, USA, 2007 (SODA '07), S. 1027–1035. DOI: www.doi.org/10.5555/1283383.1283494

- [144] HERE GLOBAL B.V.: *Guide - Routing API - HEREDeveloper*. Zuletzt geprüft: 10.12.20. URL: https://developer.here.com/documentation/routing/dev_guide/topics/introduction.html
- [145] SUNDSTROM, O.; GUZZELLA, L.: *A generic dynamic programming Matlab function*. In: *18th IEEE International Conference on Control Applications and 24th IEEE International Symposium on Intelligent Control*: IEEE, St. Petersburg, Russia, 2009, S. 1625–1630.
DOI: www.doi.org/10.1109/CCA.2009.5281131
- [146] OPENCHARGEMAP.ORG: *Open Charge Map - The global public registry of electric vehicle charging locations*. Zuletzt geprüft: 22.12.20.
URL: <https://openchargemap.org/>
- [147] NAGY, M.: *Energetic Map Data Imputation: A Machine Learning Approach*. Master Thesis. München: Technische Universität München, 2020
- [148] CUSSIGH, M.; LÖCHEL, C.; STRAUB, T.; HAMACHER, T.: *Assessing Time-Optimal Journeys: Combined Routing, Charging and Velocity Strategies for Electric Vehicles*. In: *IEEE Forum on Integrated and Sustainable Transportation System*. Delft, 2020, S. 51–57.
DOI: www.doi.org/10.1109/FISTS46898.2020.9264845
- [149] HERE: *Developer Guide - HERE Data Layers - HERE Developer*. Zuletzt geprüft: 28.02.21. URL: https://developer.here.com/documentation/data-layers/dev_guide/index.html
- [150] BEIERLE, C.; KERN-ISBERNER, G.: *Methoden wissensbasierter Systeme: Grundlagen, Algorithmen, Anwendungen*. 5., überarb. und erw. Aufl. Wiesbaden: Springer Vieweg, 2014 (Computational Intelligence).
ISBN: 978-3-8348-1896-6
- [151] THE DARK SKY COMPANY: *Dark Sky API: Documentation Overview*. Zuletzt geprüft: 08.01.21. URL: <https://darksky.net/dev/docs>
- [152] REDA, I.; ANDREAS, A.: *Solar position algorithm for solar radiation applications*. In: *Solar Energy* 76 (2004), Nr. 5, S. 577–589.
DOI: www.doi.org/10.1016/j.solener.2003.12.003

A Anhang

A.1 Aufbau digitale Karte

Das reale Straßennetz beschreibt eine digitale Karte wie die in [149] mittels eines gerichteten Graphennetzwerkes. Das gerichtete Graphennetzwerk besteht aus einzelnen gerichteten Graphen $g = \langle V, \mathcal{E} \rangle$. Ein solcher Graph setzt sich aus Ecken bzw. Knoten V zusammen, welche die Start- und Endpunkte bilden für die Kanten bzw. Links \mathcal{E} [150, S. 506]. Die Links repräsentieren die realen Straßenabschnitte. Für diese Links liegen in verschiedenen Layern beschreibende Kartenattribute vor, wie etwa Geschwindigkeitslimit, Straßenklasse, Länge des Straßenabschnitts, Steigung usw. [149]. Weist ein Straßenabschnitt in diesen Attributen neu zu beschreibenden Eigenschaften auf (z. B. Kreuzung, Ortseinfahrt mit Straßenklassenwechsel, geänderte zulässige Höchstgeschwindigkeit), so beschreibt dies die digitale Karte mit einer neuen Kante. Damit kann die digitale Karte abstrakt das reale Straßennetz beschreiben und macht es z. B. für Routingalgorithmen nutzbar.




Abb. 9.1: Beispiel eines gerichteten Graphennetzwerkes

A.2 Wetterprognose

Die Energiebedarfsprognose benötigt für die wetterabhängige Korrektur [120, betreute Abschlussarbeit] der Fahrwiderstände und des Temperierungsenergiebedarfs Informationen einer Wetterprognose. Diese stellt die Programmierschnittstelle des Online-Providers Dark Sky entlang der Geopositionen der Route zeitabhängig bereit [151]. Der Provider stellt die Wetterdaten dabei für historische Anfragen aus Wetteraufzeichnungen und für Anfragen in die Zukunft aus Prognosen bereit [151]. Die Prognosen nutzen im mitteleuropäischen Bereich der Versuchsfahrten aus 4.4.4 vornehmlich das Modell des Deutschen Wetterdienstes. Daraus bezieht die Luftwiderstandsanzpassung Informationen zur Umgebungstemperatur, Windgeschwindigkeit und -richtung sowie zu Luftfeuchte sowie -druck [120, S. 34–38]. Dagegen nutzt die initiale Rollwiderstandskorrektur nur die Umgebungstemperatur [120, S. 42]. Neben der Temperatur benötigt das Modell des Temperierungsverbrauches auch die Wolkenbedeckung, welche prozentual verfügbar ist [120, S. 43–45]. Mit der Wolkenbedeckung und der maximal örtlich und zeitlich möglichen Sonneneinstrahlungsintensität, entsprechend dem ClearSky-Modell [152], schätzt das Temperierungsmodell den Verbrauchseinfluss ab [120, 31–34].

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

Eine vollständige Übersicht der Bände finden Sie im Verlagsshop

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

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

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

- Band 103** Dominik Stretz
Vibroakustische Analyse eines elektrischen Radnabenmotors und Optimierung durch geeignete Steuerungsansätze
ISBN 978-3-7315-1245-5
- Band 104** Mohamed Elgharbawy
Measurable Safety of Automated Driving Functions in Commercial Motor Vehicles - Technological and Methodical Approaches
ISBN 978-3-7315-1254-7
- Band 105** Bernhard Schmiedel
Indirekte Schätzung des Fahrbahnneigungsgrads zur Detektion von gefährlichen Fahrzuständen
ISBN 978-3-7315-1258-5
- Band 106** 9. Fachtagung
Hybride und energieeffiziente Antriebe für mobile Arbeitsmaschinen. 28. Februar 2023, Karlsruhe
ISBN 978-3-7315-1260-8
- Band 107** Patrick Riehm
Zur Wechselwirkung zwischen Fahrbahntextur und Laufstreifenmischung von Pkw-Reifen
ISBN 978-3-7315-1268-4
- Band 108** Markus Tesar
Deep Reinforcement Learning zur Steigerung von Energieeffizienz und Pünktlichkeit von Straßenbahnen
ISBN 978-3-7315-1277-6
- Band 109** Michael Mürken
Methode zur Bewertung der Zuverlässigkeit der elektrischen Energieversorgung in der automobilen Vorentwicklung
ISBN 978-3-7315-1298-1
- Band 110** Julien Pinay
Experimental investigation of relevant road surface descriptors for tire-road noise measurements on low-absorbing road surfaces
ISBN 978-3-7315-1328-5
- Band 111** Adrian Strigel
Methode zur Ermittlung optimaler Rad- und Reifendimensionen in der frühen Entwicklungsphase von Personenkraftwagen
ISBN 978-3-7315-1321-6

- Band 112** Jens Jauch
Trajectory optimization based on recursive B-spline approximation for automated longitudinal control of a battery electric vehicle
ISBN 978-3-7315-1332-2
- Band 113** Nicolas Fraikin
Methodik zur effizienten Applikation
automatisierter Fahrfunktionen
ISBN 978-3-7315-1339-1
- Band 114** Jan Siebert
Effizienzoptimierung mobilhydraulischer Load-Sensing-Systeme
durch Reduzierung systembedingter Druckverluste am Beispiel
eines Hydraulikbaggers
ISBN 978-3-7315-1343-8
- Band 115** Tobias Sebastian Straub
Flottendatenbasierte physikalische
Routenenergiebedarfsprognose
ISBN 978-3-7315-1348-3

Um auf die Klimaziele mit energetisch planenden Funktionen in Elektrofahrzeugen hinzuarbeiten, ist entlang geplanter Strecken eine präzise, fahrtspezifische Energiebedarfsprognose unabdingbar, welche relevante Einflüsse separat quantifiziert. Nach der Identifikation solcher Einflüsse von Fahrzeug, Strecke und Fahrprofil, beschreibt diese Arbeit deren nachvollziehbare und übertragbare Modellierung. Für das physikalische Fahrzeugmodell lernt eine Fahrwiderstandsschätzung energetische Einflüsse an und korrigiert diese basierend auf einer Wetterprognose entlang der Strecke. Welchen Einfluss die Strecke und der Verkehr dabei auf das Fahrerverhalten haben, modelliert eine neuartige Fahrprofilprognose. Diese Prognose nutzt Flottendaten zu Geschwindigkeit und insbesondere zur Dynamik. Deren Einfluss auf die Energieflüsse beim Fahren und Rekuperieren erfassen dabei nur fünf Parameter. Ergänzt um Echtzeitverkehrsinformation ist diese Energiebedarfsprognose strecken-, fahrer- und fahrtspezifisch einsetzbar. Beispiele der Anwendungen zeigt diese Arbeit abschließend anhand einer Reichweitenprognose sowie einer zeitlichen Routenoptimierung, welche die Stellhebel der Ladestopplplanung und der Geschwindigkeit damit zuverlässiger nutzen kann. Über solche Anwendungen soll diese Energiebedarfsprognose die Akzeptanz und das Vertrauen in die individuelle elektrische Mobilität stärken.

