

Optimales Energiemanagement mild elektrifizierter Antriebe unter realen Betriebsbedingungen mittels Prädiktionsalgorithmen aus dem Bereich des Maschinellen Lernens

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

M. Sc.

Felix Deufel

Tag der mündlichen Prüfung:
Erster Gutachter:
Zweite Gutachterin:

05.12.2024
Prof. Dr. rer. nat. Frank Gauterin
Prof. Dr.-Ing. Nejila Parspour

Abstract

The present work deals with the optimal energy management of hybrid electric vehicles. This includes the investigation of energy management strategies (EMS) for use in system design, as well as EMS for later implementation in the vehicle. Initially, the fundamentals of hybrid electric vehicles are introduced. Also described is the modeling of the powertrain with 48 V hybridization, and the real driving cycles used are presented. Subsequently, an overview of energy management for electrified vehicles is given, focusing on the so-called Equivalent Consumption Minimization Strategy (ECMS), Dynamic Programming (DP), and Pontryagin's Minimum Principle (PMP). In addition, predictive energy management is addressed. This involves data-driven methods for predicting future torque demand, including Markov Chains (MC), as well as machine learning techniques such as Feed-forward Neural Networks (FFNN) and Recurrent Neural Networks (RNN). This first part of the work concludes with the identification of research needs.

In the main part, the focus is first on EMS in system design, where the coupling of a generic DP solution algorithm with the existing model is described. It is determined which individual advantages arise from the application of DP and Offline-ECMS. It turns out that an Offline-ECMS has significantly lower computation times, but DP can identify additional system potentials when time-variant effects occur. For use in real driving operation, an online-capable implementation of the ECMS is presented (Online-ECMS), which is the focus of the work. Unlike related concepts, the presented Online-ECMS can also be used without knowledge of the future driving speed profile, ensuring robust applicability. Subsequently, the simulation environment is used to apply the developed Online-ECMS to a model of the test vehicle for

validation and to make comparisons with the measurement data. The developed Online-ECMS shows significant savings potential compared to the EMS of the test vehicle. General recommendations for action on the existing EMS of the test vehicle can also be derived. Finally, the potentials of predictive EMS are highlighted. It turns out that RNNs, in particular, are suitable for predicting future torque. By considering map data, dynamic effects can be better predicted. In addition, two concepts of a predictive Online-ECMS are presented. It is shown how the use of predictive information can achieve additional savings potentials.

The work concludes with a summary of the most important findings. This includes an outlook both for improving the methods and regarding the transferability to battery electric vehicles (BEV).

Kurzfassung

Die vorliegende Arbeit befasst sich mit dem optimalen Energiemanagement hybridelektrischer Fahrzeuge. Dies umfasst sowohl die Untersuchung von Energiemanagementstrategien (EMS) für den Einsatz im Rahmen der Systemauslegung, als auch EMS für eine spätere Implementierung im Fahrzeug. Einleitend werden die Grundlagen hybridelektrischer Fahrzeuge eingeführt. Ebenso wird die Modellierung des Antriebsstrangs mit 48 V-Hybridisierung beschrieben und es werden die verwendeten Realfahrzyklen vorgestellt. Anschließend wird ein Überblick zum Energiemanagement elektrifizierter Fahrzeuge gegeben, wobei der Fokus auf der sogenannten Equivalent Consumption Minimization Strategy (ECMS), der Dynamischen Programmierung (DP) und dem Pontryagin'schen Minimum Prinzip (PMP) liegt. Außerdem wird auf prädiktives Energiemanagement eingegangen. Dabei werden datengetriebene Verfahren zur Vorhersage des zukünftigen Drehmomentbedarfs vorgestellt. Dies umfasst Markov-Ketten (MC), aber auch Verfahren aus dem Bereich des Maschinellen Lernens wie Vorwärtsgerichtete Neuronale Netze (FFNN) und Rekurrente Neuronale Netze (RNN). Dieser erste Teil der Arbeit schließt mit der Identifikation des Forschungsbedarfs ab.

Im Hauptteil wird zunächst auf EMS in der Systemauslegung eingegangen, wobei die Kopplung eines generischen DP-Lösungsalgorithmus mit dem bestehenden Modell beschrieben wird. Es wird herausgearbeitet, welche individuellen Vorteile sich bei der Anwendung von DP und Offline-ECMS ergeben. Dabei zeigt sich, dass die Offline-ECMS deutlich geringere Rechenzeiten aufweist, mittels der DP jedoch beim Auftreten zeitvarianter Effekte zusätzliche Systempotentiale identifiziert werden. Für den Einsatz im realen Fahrbetrieb wird eine onlinefähige Implementierung der ECMS

vorgestellt (Online-ECMS), die den Fokus der Arbeit darstellt. Im Gegensatz zu verwandten Konzepten kann die vorgestellte Online-ECMS auch ohne Kenntnis des zukünftigen Fahrgeschwindigkeitsprofils eingesetzt werden, wodurch eine robuste Einsetzbarkeit gewährleistet ist. Anschließend wird die Simulationsumgebung genutzt, um die entwickelte Online-ECMS zur Validierung auf ein Modell des Testfahrzeugs anzuwenden und Vergleiche mit den Messdaten anzustellen. Die entwickelte Online-ECMS weist signifikante Einsparpotentiale im Vergleich zur EMS des Testfahrzeugs auf. Ebenso lassen sich allgemeine Handlungsempfehlungen zur bestehenden EMS des Testfahrzeugs ableiten. Abschließend werden die Potentiale prädiktiver EMS aufgezeigt. Es stellt sich heraus, dass insbesondere RNN zur Vorhersage des zukünftigen Drehmoments geeignet sind. Durch die Berücksichtigung von Kartendaten können dynamische Effekte besser vorhergesagt werden. Darüber hinaus werden zwei Konzepte einer prädiktiven Online-ECMS vorgestellt. Dabei wird gezeigt wie durch die Nutzung prädiktiver Informationen zusätzliche Einsparpotentiale erzielt werden.

Die Arbeit schließt mit einer Zusammenfassung über die wichtigsten Erkenntnisse ab. Hierbei wird ein Ausblick sowohl zur Verbesserung der Methoden als auch hinsichtlich der Übertragbarkeit auf batterieelektrische Fahrzeuge (BEV) gegeben.

Danksagung

Die vorliegende Arbeit entstand im Rahmen meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Institut für Fahrzeugsystemtechnik des Karlsruher Instituts für Technologie im Rahmen eines kooperativen Promotionsprojekts mit der Mercedes-Benz AG in Sindelfingen. Durch die wertvolle Unterstützung vieler Personen war es möglich, die Arbeit in der vorliegenden Form zu verfassen.

Mein aufrichtiger Dank gilt Herrn Prof. Dr. rer. nat. Frank Gauterin, der das Promotionsvorhaben maßgeblich unterstützt und geprägt hat. Seine vielfältigen Anregungen und Diskussionen förderten das Verbinden wissenschaftlichen Denkens mit der praktischen Umsetzung. Frau Prof. Dr.-Ing. Nejila Parspour danke ich herzlich für die Übernahme des Korreferats. Ebenso danke ich Herrn Prof. Dr.-Ing. Tobias Düser für den Prüfungsvorsitz. Meinem Forschungsgruppenleiter Herrn Dr.-Ing. Martin Gießler möchte ich für seine wertvollen Anregungen und die uneingeschränkte Unterstützung meiner Forschungsarbeiten danken.

Innerhalb der Mercedes-Benz AG danke ich Herrn Dr.-Ing. Timo Schoenen für die bedingungslose Unterstützung unabhängig von internen Umstrukturierungen und Zuständigkeitswechseln. Durch die Förderung meiner Arbeit und sein stetiges Interesse an neuen Ansätzen sowie deren Umsetzung hatte er großen Einfluss auf den Erfolg dieser Arbeit. Herrn Dr.-Ing. Daniel Förster danke ich für die Bereitstellung seiner Vorarbeiten und die vielen Gespräche, insbesondere zu Beginn der Arbeit.

Dies hat den Verlauf des Promotionsvorhabens maßgeblich positiv beeinflusst. Auch Herrn Dr.-Ing. Lukas Decker möchte ich für seine wertvollen Impulse danken.

Viele Ideen und Ansätze entstanden durch ein hervorragendes Miteinander im Team. Meinen Kollegen, Herrn M. Sc. Clemens Kurz und Herrn M. Sc. Philip Rautenberg danke ich für die wertvollen Diskussionen und Anregungen, welche mir viel Freude bereitet haben. Wichtiger Bestandteil des Teams waren auch Studierende, die ich in den zurückliegenden drei Jahren betreuen durfte. Sie haben mit ihrer Arbeit wesentlich zum Gelingen meines Promotionsvorhabens beigetragen.

Viele fleißige Leser aus dem Kreis der Freunde und der Familie haben mich bei der Fertigstellung der Arbeit unterstützt, denen ich hiermit meinen aufrichtigen Dank aussprechen möchte. Ebenso möchte ich mich für die unermüdliche Unterstützung während der gesamten Forschungsarbeit bedanken.

Karlsruhe, im März 2023

Felix Tobias Deufel

Inhaltsverzeichnis

Abstract	i
Kurzfassung	iii
Danksagung	v
Abkürzungs- und Symbolverzeichnis	xi
1 Einleitung	1
1.1 Motivation	1
1.2 Zielsetzung und Forschungsfragen	3
1.3 Aufbau der Arbeit	5
2 Hybridelektrische Fahrzeuge (48 V)	9
2.1 Topologien, Betriebsarten und Hybridisierungsgrad	9
2.2 Das 48 V-System	10
2.3 Systemmodellierung	12
2.3.1 Modellierung des Antriebsstrangs	12
2.3.2 Realfahrzyklen	20
2.3.3 Zwischenfazit Systemmodellierung	22
3 Energiemanagement elektrifizierter Fahrzeugantriebe	23
3.1 Übersicht Energiemanagementstrategien (EMS)	24
3.2 Dynamische Programmierung (DP)	29
3.3 PMP und ECMS	33
3.4 Prädiktives Energiemanagement	38
3.4.1 Grundlagen der Modellpräd. Regelung (MPC)	39

3.4.2	Prädiktion realer Fahrgeschwindigkeitsprofile . . .	42
3.4.3	Prädiktive EMS	50
3.5	Forschungsbedarf EMS (48 V)	52
4	Energiemanagement in der Systemauslegung (48 V)	57
4.1	Systemauslegung mittels Offline-ECMS	57
4.2	Erweiterung des Fahrzeugmodells um die DP	61
4.2.1	Steuergröße u	62
4.2.2	Zustandsgröße x	65
4.2.3	Kostenfunktion C und unzulässige Zustände I . . .	69
4.2.4	Vergleich DP und Offline-ECMS	71
4.3	DP und Offline-ECMS bei zeitvarianten Systemen	75
4.3.1	Berücksichtigung von VKM-Starts	75
4.3.2	Batteriedimensionierung	80
4.4	Zwischenfazit EMS in der Systemauslegung	82
5	Energiemanagement im realen Fahrbetrieb (48 V)	85
5.1	Robuste, nichtprädiktive Online-ECMS	87
5.1.1	Basislambda für Online-ECMS	88
5.1.2	Straffaktor k_{pSOC} für Online-ECMS	90
5.1.3	Ergebnisse	94
5.2	Anwendung der Online-ECMS auf Realmessfahrten	97
5.2.1	Verfügbarer Datensatz und Verifizierung	97
5.2.2	Parametrieren des Modells auf Testfahrzeug	99
5.2.3	Validierung und Handlungsempfehlungen	114
5.3	Implementierung und Echtzeitfähigkeit	126
5.4	Zwischenfazit EMS im realen Fahrbetrieb	128
6	Potentiale präd. Energiemanagementstrategien (48 V) . . .	131
6.1	Prädiktion mittels datengetriebener Verfahren	132
6.1.1	Markov-Ketten (MC)	133
6.1.2	Vorwärtsgg. Neuronale Netzwerke (FFNN)	133
6.1.3	Rekurrente Neuronale Netzwerke (RNN)	135
6.2	Vergleich und Diskussion der Prädiktionen	137
6.3	Konzeption einer prädiktiven Online-ECMS	143

6.4	Zwischenfazit Potentiale prädiktiver EMS	150
7	Zusammenfassung und Ausblick	153
7.1	Zusammenfassung	153
7.2	Ausblick	155
	Literatur	157
	Eigene Publikationen	179
	Betreute studentische Arbeiten	181
	Abbildungsverzeichnis	183
	Tabellenverzeichnis	197
 Anhang		
A	Praxisbeispiel DP: Rechenalgorithmus	203
B	Praxisbeispiel DP: Matrizenarchitektur	207
C	Theoretischer Hintergrund PMP und Praxisbeispiel	209
D	Simulationsergebnisse: Offline-ECMS und DP	219
E	Zielkonflikt Fahrkomfort ggü. CO ₂ : ECMS und DP	223
F	Ergänzende Informationen zur Online-ECMS	225
G	Dauerläuferdaten zur Validierung der Online-ECMS	229
H	Übersicht alternative Realfahrdaten	235
I	Praxisbeispiel: Aufbereitung von Realfahrdaten	239
J	Parametrierung Markov-Ketten und Neuronale Netze	249

Abkürzungs- und Symbolverzeichnis

Abkürzungen

<i>ACO</i>	Ameisenalgorithmus (<i>Ant Colony Optimization</i>)
<i>ADP</i>	Approximierte Dynamische Programmierung
<i>AI</i>	Künstliche Intelligenz (<i>Artificial Intelligence</i>)
<i>ANN</i>	Künstliches Neuronales Netz (<i>Artificial Neural N.</i>)
<i>APP</i>	Fahrpedalstellung (<i>Accelerator Pedal Position</i>)
<i>BAT</i>	Batterie
<i>BEV</i>	Batterieelektr. Fahrzeug (<i>Battery Electric Vehicle</i>)
<i>BMS</i>	Batteriemanagementsystem
<i>CAN</i>	Serielles Bussystem (<i>Controller Area Network</i>)
<i>CS</i>	Kurbelw. (<i>Crank Shift.</i>) / Ladungserh. (<i>Chrg. Sust.</i>)
<i>C2C</i>	Kommunikation Fzg. (<i>Car-to-Car-Communication</i>)
<i>C2X</i>	Kommunikation Fzg. (<i>Car-to-everything-Comm.</i>)
<i>DP</i>	Dynamische Programmierung
<i>DT</i>	Differentialgetriebe
<i>DTMC</i>	Zeitdiskrete Markov-Kette (<i>Discrete-Time MC</i>)
<i>ECMS</i>	Equivalent Consumption Minimization Strategy
<i>ED – LSTM</i>	LSTM mit Encoder und Decoder
<i>EM</i>	Elektromotor
<i>EMS</i>	Energiemanagementstrategie

<i>ESB</i>	Ersatzschaltbild der Batterie
<i>ETH</i>	Eidgenössische Technische Hochschule Zürich
<i>FAST</i>	Institut für Fahrzeugsystemtechnik
<i>FFNN</i>	Vorwärtsgerichtetes NN (<i>Feed Forward Neural N.</i>)
<i>GA</i>	Genetischer Algorithmus
<i>GB</i>	Getriebe (<i>Gearbox</i>)
<i>GNSS</i>	Globales Navigationssatellitensystem
<i>GRU</i>	Gated Recurrent Units, Unterform der RNN
<i>ID</i>	Kennzeichnung (<i>Identification</i>)
<i>KAT</i>	Katalysator
<i>KBA</i>	Kraftfahrt-Bundesamt
<i>KW</i>	Kurbelwelle
<i>LE</i>	Leistungselektronik
<i>LPAn</i>	Lastpunkterhöhung bei VKM, Spezialfall der LPV
<i>LPAb</i>	Lastpunktverringern bei VKM, Spezialfall der LPV
<i>LPV</i>	Lastpunktverschiebung bei VKM
<i>LSTM</i>	Lang. Kurzzeitgedächtn. (<i>Long Short-Term Memory</i>)
<i>MC</i>	Markov-Kette (<i>Markov Chain</i>)
<i>MPC</i>	Modellpräd. Regelung (<i>Model Predictive Control</i>)
<i>MSE</i>	Mittlerer Quadratischer Fehler (<i>Mean Squared Error</i>)
<i>NN</i>	Neuronales Netz (<i>Neural Network</i>)
<i>NPM</i>	Nichtparametrische Methoden
<i>NV</i>	Nebenverbraucher
<i>OSM</i>	Open Street Map
<i>PM</i>	Parametrische Methoden
<i>PMP</i>	Pontryagin'sches Minimum-Prinzip
<i>PSO</i>	Partikelschwarmoptimierung
<i>ReLU</i>	<i>Rectified Linear Unit</i> , Aktivierungsfunktion ANN
<i>RL</i>	Bestärkendes Lernen (<i>Reinforcement Learning</i>)

<i>RMSE</i>	Wrzl. mittl. Fehlerquad. Sum. (<i>Root Mean Squared Err.</i>)
<i>RNN</i>	Rekurrentes NN (<i>Recurrent NN</i>)
<i>SM</i>	Schießverfahren für Offline-ECMS (<i>Shooting Method</i>)
<i>SMPC</i>	Stoch. Modellpräd. R. (<i>Stochastic Model Pred. Contrl.</i>)
<i>SOC</i>	Ladezustand der Batterie (<i>State of Charge</i>)
<i>SRTM</i>	Shuttle Radar Topography Mission
<i>TPM</i>	Übergangswahrs. M. (<i>Transition Probability Matrix</i>)
<i>VKM</i>	Verbrennungskraftmaschine
<i>WLTC</i>	Worldwide harmonized Light Duty Test Cycle

Lateinische Symbole

a	Fahrzeugbeschleunigung	m/s^2
a_{avg}	Mittlere Fahrzeugbeschleunigung	m/s^2
a_{ij}	Übergangswahrslk. vom Zustand S_i zu S_j (MC)	—
a_{max}	Max. Fahrzeugbeschleunigung	m/s^2
a_{min}	Min. Fahrzeugbeschleunigung	m/s^2
A	Projizierte Querschnittfläche	m^2
b	Bias (FFNN)	—
c_w	Luftwiderstandsbeiwert	—
C	Nennkapazität einer Batterie / Kostenfunktion (DP)	As —
C_k	Instantane Kosten zum Zeitpunkt k, auch L_k (DP)	—
C_t	Zellzustand zum Zeitpunkt t (LSTM)	—
C_{t-1}	Zellzustand zum Zeitpunkt t-1 (LSTM)	—
\tilde{C}_t	Kandidat für Zellzustand zum Zeitpunkt t (LSTM)	—
$CO_{2,basic}$	CO ₂ -Emissionen aus Modell - Basis	g/km
$CO_{2,corr}$	CO ₂ -Emissionen aus Modell - Korrigiert	g/km
d	Anz. Merkmale / Anz. Eingänge (FFNN) / Distanz	— km

d_{total}	Gesamtdistanz	km
ds	Streckenabschnitt zur Kurvenbestimmung	m
dt	Zeitschritt allg.	s
dE_{bat}	Energieänderung der Batterie	$J \mid Wh$
$dSOC$	Änderung des Ladezustands der Batterie	-
dT	Zeitschritt (diskret) / Simulationszeitschritt	s
$d\phi$	Änderung Peilung zur Kurvenbestimmung	$^\circ$
E_{bat}	Nutzbarer Energieinhalt einer Batterie	Wh
E_{min}	Rekuperierte Mindestenergie (Präd. Online-ECMS)	Wh
$E_{stsp,hyst}$	Energie zur Vermeidung eines VKM-Start/Stop	Wh
$E_{stsp,hyst,max}$	Maximal zul. Energie Vermeidung VKM-Start/Stop	Wh
E_{CS}	Mechanischer Energiebedarf an der KW	kWh
$f(...)$	Allgemeine Funktion	-
$f_k(...)$	Allgemeine Funktion (diskret)	-
f_r	Rollwiderstandsbeiwert	-
f_t	Ausgang des <i>Forget Gates</i> (LSTM)	-
$f_{willans}$	Willans-Funktion	kg/s
F_{acc}	Beschleunigungswiderstandskraft	N
F_{air}	Luftwiderstandskraft	N
F_{roll}	Rollwiderstandskraft	N
F_{wheel}	Fahrwiderstandskraft am Rad	N
F_{α}	Steigungswiderstandskraft	N
$f_{gCV,k}$	Flag Kurve zum Zeitpunkt k (ED-LSTM)	-
$f_{gGW,k}$	Flag Vorfahrt gew. zum Zeitpunkt k (ED-LSTM)	-
f_{gTS}	Flag Ampel (Präd. Online-ECMS)	-
$f_{gTS,k}$	Flag Ampel zum Zeitpunkt k (ED-LSTM)	-
g	Erdbeschleunigung	m/s^2
h_t	Verborgener Zustand im aktuellen Zeitschr. (ANN)	-
h_{t-1}	Verborgener Zustand im letzten Zeitschr. (RNN)	-

H	Hamiltonfunktion (PMP)	kg/s
H_u	Unterer Heizwert	(kJ)/kg
i	Zeitschritt in einem zeitdiskreten Problem	–
i_t	Ausgang des <i>Input Gates</i> (LSTM)	–
I	Unzuläss. Zust. (DP) / Anz. Zustandsgr. (DP)	–
I_{bat}	Batteriestrom	A
J	Kostenfunktion (DP)	–
J^*	Kosten für optimale Steuerung (DP)	–
k	Zeitindex in einem zeitdiskreten Problem	–
K	Anzahl Steuergrößen (DP)	–
kp_{stsp}	Bestrafung Zustandsübergang Start/Stop der VKM	-
kp_{SOC}	Bestrafung SOC-Abweichung bei Online-ECMS	-
$kp_{SOC,CS}$	Bestrafung SOC-Abweichung um CS zu erfüllen	-
kp_{pred}	Proportionalitätsfaktor Reku. (Präd. Online-ECMS)	1/Wh
kp_{TS}	Proportionalitätsfaktor Ampel (Präd. Online-ECMS)	–
L	Instantane Kosten	– kg/s
L_k	Instantane Kosten zum Zeitpunkt k, auch C_k (DP)	–
L_N	Kosten im finalen Zeitschritt N (DP)	–
m	Fahrzeugmasse	kg
\dot{m}_{eqv}	Äquivalenter Kraftstoffmassenstrom	kg/s
$\dot{m}_{eqv,ICE,stsp}$	Äqu. Kraftstoffmassenstr. inkl. Starts/Stopps VKM	kg/s
$\dot{m}_{fuel,k}$	Kraftstoffmassenstrom um Zeitpunkt k	kg/s
\dot{m}_{fuel}	Kraftstoffmassenstrom	kg/s
n_{wheel}	Raddrehzahl	1/min
n_{CS}	Kurbelwellendrehzahl	1/min
n_{EM}	Drehzahl EM	1/min
n_{ICE}	Drehzahl VKM (<i>Internal Combustion Engine</i>)	1/min
$n_{ICE,max}$	Maximale Drehzahl VKM (<i>Internal Combustion E.</i>)	1/min
N	Anz. Zeitschritte Optimierungsprbl. / Zustände (MC)	–

N_{cycle}	Anzahl Zeitschritte Fahrzyklus	—
$N_{horizon}$	Anz. Zeitschritte für Präd. Horizont τ_{pred}	—
$N_{neurons,IL}$	Anz. Neuronen in Eingangsschicht (<i>Input Layer</i>)	—
$N_{neurons,OL}$	Anz. Neuronen in Ausgangsschicht (<i>Output Layer</i>)	—
$N_{neurons,HL,i}$	Anz. Neuronen in verst. Schicht i (<i>Hidden Layer</i>)	—
N_{HL}	Anz. versteckte Schichten (<i>Hidden Layer</i>)	—
N_U	Allg. Anzahl Stützstellen Steuergröße (DP)	—
N_{U_i}	Stützstellenanzahl des Steuergröße U_i (DP)	—
N_X	Allg. Anzahl Stützstellen Zustandsgröße (DP)	—
N_{X_i}	Stützstellenanzahl der Zustandsgröße X_i (DP)	—
o_t	Ausgang Output Gate (LSTM)	—
O	Obere asymptotische Schranke der Komplexität (DP)	—
P_{recu}	Rekuperierbare Energie in Prädiktionshorizont	Wh
P_{aux}	Nebenverbraucherleistung	kW
$P_{aux,avg}$	Mittlere Nebenverbraucherleistung	kW
$P_{aux,median}$	Median Nebenverbraucherleistung	kW
P_{bat}	Klemmenleistung der Batterie	$W \mid kW$
$P_{bat,loss}$	Verlustleistung Batterie	W
$P_{bat_{dis}}/P_{EM_{mot}}$	Entladung BAT, Mot. Betrieb EM (NV-Bestimmung)	—
$P_{bat_{dis}}/P_{EM_{gen}}$	Entladung BAT, Gen. Betrieb EM (NV-Bestimmung)	—
$P_{bat_{chg}}/P_{EM_{gen}}$	Ladung BAT, Gen. Betrieb EM (NV-Bestimmung)	—
$P_{bat_{chg}}/P_{EM_{mot}}$	Ladung BAT, Mot. Betrieb EM (NV-Bestimmung)	—
P_{eqv}	Äquivalenzleistung (ECMS)	W
P_{fuel}	Leistung aus dem Kraftstoffmassenstrom	W
P_{req}	Geforderte Leistung (allg.)	W
$P_{wheel,ges}$	Gesamte Leistung am Rad	kW
$P_{wheel,recu,EM24}$	Ges. recup. Leistung Rad (EM in P2- und P4-Pos.)	kW
$P_{CS,recu,EM2}$	Rekuperierte Leistung KW durch EM in P2-Position	kW
$P_{CS,ges}$	Gesamte Leistung an der Kurbelwelle	kW

P_{CS}	Leistung an Kurbelwelle allg.	kW
P_{ICE}	Leistung VKM (<i>Internal Combustion Engine</i>)	kW
$P_{ICE,drag}$	Schleppleistung VKM (<i>Internal Combustion Engine</i>)	kW
P_{TPM}	Übergangswahrscheinlichkeit (MC)	—
q_t	Zustand zum Zeitpunkt t (MC)	—
r_{dyn}	Dynamischer Radhalbmesser	m
$r_{dyn,eff}$	Effektiv wirkender Dynamischer Radhalbmesser	m
$r_{dyn,theo}$	Theor. Dynamischer Radhalbmesser (Datenblatt)	m
R	Radius (allgemein)	m
R^2	Bestimmtheitsmaß	—
R_i	Innerer Widerstand ESB	Ω
$R_{Adenauerring}$	Radius Adenauerring, Karlsruhe	m
RMS_a	Effektivwert Beschleunigung	m/s^2
RMS_v	Effektivwert Geschwindigkeit	km/h
RMS_α	Effektivwert Steigung	%
$RMSE_a$	Mittlere Quadratische Abweichung Beschl.	m/s^2
$RMSE_v$	Mittlere Quadratische Abweichung Geschw.	km/h
$RMSE_\alpha$	Mittlere Quadratische Abweichung Steigung	%
s	Äquivalenzfaktor der ECMS / Schlupf	—
S_i	Zustand allgemein in MC	—
SOC	Ladezustand der Batterie	—
\dot{SOC}	Änderung des Ladezustands der Batterie	$1/s$
SOC_f	Finaler Ladezustand Batterie	—
SOC_{init}	Initialladezustand	—
$SOC_{init,meas.}$	Initialladezustand aus Messung	—
SOC_{max}	Maximaler Ladezustand Batterie	—
SOC_{min}	Minimaler Ladezustand Batterie	—
$\frac{\partial \dot{SOC}}{\partial SOC}$	Ableitung Ladezustandsänderung nach Ladezustand	$1/s$
t	Zeit	s

t_f	Finaler Zeitschritt	—
t_k	Zeit (diskretisiert)	s
T_{brake}	Drehmoment mechanische Bremse	Nm
T_{req}	Allg. Drehmomentanforderung aus Längsdynamik	Nm
$T_{req,wheel}$	Drehmomentanforderung am Rad	Nm
$T_{req,CS}$	Drehmomentanforderung an der Kurbelwelle	Nm
T_{CS}	Drehmoment Kurbelwelle (<i>Crank Shaft</i>)	Nm
$T_{CS,model}$	Drehmoment Kurbelwelle Modell	Nm
$T_{CS,meas.}$	Drehmoment Kurbelwelle Messung	Nm
$T_{ICE,meas.}$	Drehmoment VKM	Nm
T_{EM}	Drehmoment EM	Nm
$T_{EM,gen,max}$	Maximales generatorisches Drehmoment EM	Nm
$T_{EM,mot,max}$	Maximales motorisches Drehmoment EM	Nm
$T_{GB,loss}$	Getriebeverlustrmoment	Nm
T_{ICE}	Drehmoment VKM	Nm
$T_{ICE,avg}$	Mittleres Drehmoment VKM	Nm
$T_{ICE,drag}$	Schleppdrehmoment VKM	Nm
$T_{ICE,max}$	Maximales Drehmoment VKM	Nm
u	Steuergröße (allgemein)	—
u^*	Optimale Steuerung (DP)	—
u_k	Steuergröße im Zeitschritt k	—
U_{bat}	Klemmenspannung Batterie	V
U_{OCV}	Open Circuit Voltage / Leerlaufspannung ESB	V
v	Fahrzeuggeschwindigkeit	m/s km/h
v_{avg}	Mittlere Fahrzeuggeschwindigkeit	km/h
v_k	Geschwindigkeit zum Zeitpunkt k (ED-LSTM)	km/h
v_{max}	Max. Fahrzeuggeschwindigkeit	km/h
v_{max_k}	Zul. Höchstgeschw. zum Zeitpunkt k (ED-LSTM)	km/h
$v_{upshift}$	Hochschaltgeschwindigkeit	km/h

w_i	Gewichtung einer Verbindung (FFNN)	—
W	Gewichtungen der Verbindungen (FFNN)	—
W_{hh}	Gew. verborgener Zustd. zu verborg. Zustd. (RNN)	—
W_{xh}	Gew. Eingang zu verborgener Zustd. (RNN)	—
W_{hy}	Gew. verborgener Zustd. zu Ausgang (RNN)	—
x	Zustand (allgemein)	—
\dot{x}	Zustandsänderung (allgemein)	—
\dot{x}^*	Zustandsänderung optimale Lösung (allgemein)	—
$x_{f,min}$	Zulässiger Minimalwert finaler Zeitschritt (DP)	—
$x_{f,max}$	Zulässiger Höchstwert finaler Zeitschritt (DP)	—
x_j	Eingang (FFNN)	—
x_k	Zustand im Zeitschritt k	—
x_N	Zustand im finalen Zeitschritt N	—
x_0	Initialwert Zustand x	—
X	Eingangswerte (FFNN)	—
X_1	Batterieladezustand SOC (DP)	—
X_2	VKM-Laufzeit (DP)	s
$X_{2,k}$	Laufzeit VKM zum Zeitpunkt k	s
X_3	VKM-Zustand An/Aus (DP)	—
$X_{3,k}$	Zustand VKM zum Zeitpunkt k	—
\hat{y}	Ausgang (FFNN)	—
Y	Kosten bis zur Zielerreichung (<i>Cost-To-Go</i>) bei DP	— kg

Griechische Symbole

α	Fahrbahnsteigung aus Fahrzyklus	%
α_k	Fahrbahnsteigung zum Zeitpunkt k (ED-LSTM)	%
α_{max}	Maximale Fahrbahnsteigung	%

α_{min}	Minimale Fahrbahnsteigung	%
Δ_a	Diskretisierung Fahrzeugbeschleunigung (MC)	m/s^2
Δ_v	Diskretisierung Fahrzeuggeschwindigkeit (MC)	km/h
$\Delta_{CO_2,avg}$	Mittlere CO ₂ Abw. Online-ECMS zum Optimum	%
Δ_{SOC}	Differenz (Batterie-)ladezustand (allg.)	—
Δ_α	Diskretisierung Fahrbahnsteigung (MC)	%
ΔE_{CS}	Abweichung Batterieenergie zum Initialzustand	Wh
$\Delta E_{CS,end}$	Endenergieabw. Batterie zum Fahrtende ggü. CS	$Wh \mid kJ$
$\Delta E_{CS,min,max}$	Diff. min./max. Abw. der Batterieenergie ggü. CS	Wh
$\Delta E_{CS,min}$	Min. Abw. Batterieenergie zum Initialzustand	Wh
$\Delta E_{CS,max}$	Max. Abw. Batterieenergie zum Initialzustand	Wh
ΔSOC_{CS}	Abweichung SOC zum Intialladezustand	—
$\Delta SOC_{min,max}$	Differenz min./max. Batterieladezustände	—
η_{bat}	Wirkungsgrad Batterie (allgemein)	—
$\eta_{corr,ges,overc.}$	Durchschnittl. Wirkungsgrad Korr. Überladung	—
$\eta_{corr,ges,underc.}$	Durchschnittl. Wirkungsgrad Korr. Unterladung	—
η_{coul}	Coulomb. Wirkungsgrad Batterie	—
η_{EM}	Wirkungsgrad EM	—
η_{ICE}	Wirkungsgrad VKM	—
κ	Krümmung im Rahmen der Kurvenbestimmung	$^\circ/m$
$\kappa_{eqv,SOC}$	Batterieladezustandsäquivalenzfaktor	$1/(Nm \cdot s)$
λ	Äquivalenzfaktor	—
λ_{eff}	Effektiver Äquivalenzfaktor für (Online-ECMS)	—
λ_{PMP}	Co-State (PMP)	kg
$\dot{\lambda}_{PMP}$	Änderung Co-State (PMP)	kg/s
$\lambda_{PMP,0}$	Initialer Co-State (PMP)	kg
$\lambda_{PMP,0}^*$	Optimaler Wert für den initialen Co-State (PMP)	kg
λ_0	Initialer Äquivalenzfaktor (Offline-ECMS)	—
$\lambda_{0,avg}$	Gemittelter Äquivalenzfaktor (Online-ECMS)	—

μ_{inf}	Kosten für unzulässige Zustände (DP)	kg/s
μ^*	Optimale Steuerungsmatrix (DP)	—
ϕ	Peilung zur Kurve / Endkosten (DP)	° —
ρ	Luftdichte	kg/m ³
ρ_{fuel}	Kraftstoffdichte	kg/l
σ	Sigmoid Aktivierungsfunktion (LSTM)	—
$\tau_{control}$	Dauer Steuerungshorizont (MPC)	s
τ_{pred}	Dauer Prädiktionshorizont (MPC)	s
$\tau_{standstill}$	Standzeit	%
τ_{total}	Gesamtdauer	h
$\tau_{ICE,min}$	VKM-Mindestlaufzeit (<i>Internal Combustion Engine</i>)	s
θ	Aktivierungsfunktion (FFNN)	—
$\theta_{outside}$	Außentemperatur	°C
$\theta_{outside,avg}$	Gemittelte Außentemperatur	°C

Individuelle Abweichungen von den hier angegebenen Einheiten sind im Fließtext entsprechend kenntlich gemacht.

1 Einleitung

Im Rahmen dieses Kapitels wird zunächst die Motivation für die vorliegende Arbeit beschrieben (Kapitel 1.1). Anschließend wird die Zielsetzung der Arbeit aufgezeigt sowie die zentrale Forschungsfrage bzw. die damit verbundenen Forschungsfelder vorgestellt (Kapitel 1.2). Abschließend wird ein Überblick zum Aufbau der Arbeit gegeben (Kapitel 1.3).

1.1 Motivation

Zunehmend strengere Emissionsgrenzwerte (u. a. Euro-7-Abgasnorm ab 2025) und das insgesamt gestiegene Umweltbewusstsein haben zur Entwicklung verschiedener alternativer Antriebe geführt. Dazu gehören neben reinen Elektrofahrzeugen auch 48 V-Hybrid-Elektrofahrzeuge (HEV), die den großen Vorteil bieten, den CO₂-Ausstoß - bei innerstädtischen Fahrten - mit vergleichsweise geringem Systemaufwand deutlich zu reduzieren [För24], vgl. Deufel et al. [2]. Ein solches 48 V-System wird durch seine Komponenten, die gewählte Topologie, also die Anordnung der Komponenten, sowie die zugehörige Energiemanagementstrategie (EMS) charakterisiert [Sil16b]. Die notwendigen Schritte zur Entwicklung eines 48 V-Systems lassen sich anhand des weit verbreiteten *V-Modells* nach VDI 2206 [Gau02] aus dem *Systems Engineering* beschreiben (Abbildung 1.1). Bei diesem Modell bestehen zunächst Anforderungen an das zu entwickelnde Produkt. Hieraus muss auf die Anforderungen an die Komponenten geschlossen werden, sodass die entsprechenden Funktionen entwickelt und mittels zugehöriger Software implementiert werden können. Anschließend erfolgt die Systemintegration durch Komponenten- und Integrationstests. Dabei werden die Eigenschaften

des zu entwickelnden Produkts stetig abgesichert. Nach mehreren Iterationen im V-Modell ist das Produkt entsprechend den Anforderungen fertig entwickelt.




Abbildung 1.1: Allgemeines V-Modell aus dem *Systems Engineering* mit Fokus der vorliegenden Arbeit. Angelehnt an VDI 2206 [Gau02].

Beim Systementwurf, bei der Komponententwicklung, aber auch bei der späteren Implementierung im Fahrzeug ist eine optimale EMS entscheidend. Durch einen optimalen Betrieb der einzelnen Komponenten bestimmt diese das größtmögliche Kraftstoffeinsparpotential. Es können aber auch zusätzliche Optimierungsziele wie ein möglichst hoher Fahrkomfort bestehen. Im Rahmen der Systemauslegung muss die theoretisch optimale EMS bestimmt werden, um die individuellen Potentiale verschiedener Antriebsstrangkonfigurationen bewerten zu können. Im Hinblick auf eine spätere Implementierung entsprechend dem V-Modell, gilt es auch im Onlinebetrieb ein möglichst optimales Zusammenspiel der Komponenten sicherzustellen. Hierfür wird eine Übertragbarkeit entsprechender Ansätze aus der Systemauslegung untersucht. Prädiktive Ansätze und der Einsatz des Maschinellen Lernens gelten

dabei als besonders vielversprechend [Tra20]. Die gesamtheitliche Betrachtung von der Systemauslegung bis zum Betrieb im Fahrzeug garantiert dabei ein stets optimales Zusammenspiel der Komponenten über den gesamten Entwicklungsprozess.

1.2 Zielsetzung und Forschungsfragen

Die vorliegende Dissertationsschrift erarbeitet durch simulative Untersuchungen EMS für den Einsatz in 48 V-Systemen, die sowohl im Rahmen der Systemauslegung wie auch bei der späteren Implementierung im realen Fahrzeug eine maximale Verbrauchsreduktion bzw. damit einhergehende CO₂-Reduktion ermöglichen. Dabei werden auch zusätzliche Kriterien wie ein hoher Fahrkomfort berücksichtigt. Basierend auf einem umfassenden Überblick zum allgemeinen Stand der Forschung hinsichtlich EMS für elektrifizierte Fahrzeugantriebe, werden dabei ausgewählte Methoden auf 48 V-Systeme in verschiedenen Topologien angewendet und hinsichtlich Aufwand und Nutzen analysiert. Im Fokus der Arbeit steht die Entwicklung einer robusten onlinefähigen EMS für den Einsatz im realen Fahrzeug, welche mit den Messdaten eines Testfahrzeugs in P1-Topologie validiert wird. Abschließend werden die Potentiale ausgewählter prädiktiver Methoden aufgezeigt. Im Rahmen der Arbeit wird unter einer Prädiktion die Vorhersage des zukünftigen Fahrgeschwindigkeitsprofils bzw. die Prognose signifikanter Einflüsse im laufenden Fahrbetrieb verstanden. Letzteres kann beispielsweise das mit dem Vorhandensein einer Ampel in Verbindung stehende Rekuperationspotential infolge des jeweiligen Bremsvorgangs bedeuten. Mit einem entsprechenden Optimierer können die vorausliegenden, prädizierten Gegebenheiten bereits in der aktuellen Steuerentscheidung berücksichtigt werden. Das Fahrzeug wird dann so gesteuert, dass es später einen bestimmten Zustand einnimmt. Mittels entsprechender Maßnahmen kann dabei ein recheneffizienter Onlinebetrieb des Optimierers im Fahrzeug realisiert werden. Eine onlinefähige EMS kann also prädizierte Informationen mitberücksichtigen, jedoch wird eine Prädiktion zukünftiger Informationen

im Rahmen dieser Arbeit als nicht zwingend erforderlich für einen Onlinebetrieb angesehen. In der Arbeit wird daher eine Trennung zwischen der Prädiktion selbst und dem verwendeten Optimierer vorgenommen. An dieser Stelle sei darauf hingewiesen, dass sich Optimierungsprobleme im Rahmen der Arbeit stets auf die optimierte Nutzung von VKM und EM beschränken. Eine Optimierung des zugrunde liegenden Geschwindigkeitsverlaufs selbst entfällt, da im Fokus der Arbeit die Untersuchung realer, durch einen Fahrer vorgegebener Fahrgeschwindigkeitsprofile steht. Ein besonderer Fokus bei der Untersuchung der Potentiale ausgewählter prädiktiver Methoden, also Verfahren zur Vorhersage vorausliegender Gegebenheiten, liegt auf Ansätzen aus dem Bereich des Maschinellen Lernens. Im Gegensatz zum Onlinebetrieb, erübrigt sich die Herausforderung einer Vorhersage im laufenden Fahrbetrieb in der Offline-Systemauslegung. Hier ist grundsätzlich das gesamte Fahrgeschwindigkeitsprofil bekannt. Die zentrale Forschungsfrage lautet damit:

Wie lässt sich sowohl im Rahmen der Systemauslegung als auch bei der späteren Implementierung im Fahrzeug ein möglichst optimaler Betrieb eines hybridelektrischen Antriebsstrangs (48 V-System) sicherstellen und welche Verbesserungen lassen sich dabei durch den Einsatz prädiktiver Verfahren aus dem Bereich des Maschinellen Lernens erzielen?

Diese zentrale Forschungsfrage deckt insgesamt drei Forschungsfelder ab:

Forschungsfeld 1: EMS in der Systemauslegung (Offline-Anwendung)

Welche EMS eignen sich um im Rahmen der Systemauslegung für verschiedene Topologien den optimalen Betrieb zu finden? Welche individuellen Vor- und Nachteile ergeben sich bei den jeweiligen EMS, bei der Betrachtung mehrerer Zustände und beim Vorliegen zeitvarianter Effekte? Welcher Zielkonflikt resultiert hieraus?

Forschungsfeld 2: EMS im realen Fahrbetrieb (Online-Anwendung)

Wie lässt sich eine onlinefähige EMS entwickeln, die einen robusten Einsatz im Realfahrzeug in Echtzeit erlaubt, ohne Kenntnis des vorausliegenden Fahrgeschwindigkeitsprofils? Kann der Fahrkomfort - beispielsweise repräsentiert

durch die Starts der Verbrennungskraftmaschine (VKM) - im Optimierungsproblem in geeigneter Weise berücksichtigt werden? Welcher Zielkonflikt lässt sich aufzeigen? Kann eine Echtzeitfähigkeit nachgewiesen werden? Kann die entwickelte EMS durch die Analyse von Realmessfahrten des Testfahrzeugs validiert werden? Worin unterscheidet sich die entwickelte onlinefähige EMS von der EMS des Testfahrzeugs? Wie verhält sich die EMS des Testfahrzeugs im Vergleich zum theoretischen Optimum?

Forschungsfeld 3: Potentiale prädiktiver EMS unter Verwendung des Maschinellen Lernens (Online-Anwendung)

Ist eine Verbesserung der robusten, nichtprädiktiven Online-ECMS durch eine Vorhersage des vorausliegenden Fahrgeschwindigkeitsprofils grundsätzlich möglich? Wenn ja, in welchen Fällen? Wie lässt sich eine solche prädiktive EMS entwickeln? Wie können die notwendigen Prädiktionen für Realfahrten erfolgen? Wie verhalten sich statistische Verfahren gegenüber Verfahren aus dem Bereich des Maschinellen Lernens zur Vorhersage des vorausliegenden Fahrgeschwindigkeitsprofils? Lässt sich eine Verbesserung der Kraftstoffeinsparpotentiale nachweisen?

1.3 Aufbau der Arbeit

Zunächst wird in Kapitel 2 das 48 V-System als Teil eines hybridelektrischen Fahrzeugs (HEV) eingeordnet und seine Wechselwirkungen aufgezeigt. Daraus ergibt sich für die simulativen Untersuchungen der Bedarf nach einer Modellierung des Antriebsstrangs und einer Abbildung des realen Betriebs durch entsprechende Fahrzyklen. Anschließend wird ein Überblick über den Stand der Forschung von EMS (Kapitel 3) gegeben. Dabei werden vielversprechende Methodiken aus dem Stand der Forschung identifiziert. Diese bilden die Basis zur Entwicklung neuer, eigener Ansätze zur Beantwortung der Forschungsfragen. Im Speziellen wird auf die Verfahren Dynamische Programmierung (DP), Pontryagin'sches Minimum-Prinzip (PMP) und Equivalent Consumption Minimization Strategy (ECMS) eingegangen. Das Themenfeld der prädiktiven EMS sowie die hiermit verbundenen Prädiktionsalgorithmen

werden in einem separaten Abschnitt beschrieben. Nach der abschließenden Identifikation des Forschungsbedarfs und einer Abgrenzung verwandter Arbeiten wird im Folgenden die bereits in Deufel et al. [2] vorgestellte Methodik vertieft und erweitert. In Kapitel 4 wird hierfür zunächst auf EMS zur Systemauslegung eingegangen. Anschließend wird in Kapitel 5 die Entwicklung einer EMS für den Einsatz im realen Fahrzeug beschrieben. Die entwickelte Online-ECMS bildet den Schwerpunkt der Arbeit und wird umfassend mittels Messdaten validiert. Anschließend werden in Kapitel 6 die Potentiale prädiktiver Ansätze untersucht. Zusammenfassung und Ausblick in Kapitel 7 runden die Untersuchungen ab. Ein Überblick ist in Abbildung 1.2 gegeben. Hier sind auch die verwendeten Softwares und Toolboxes aufgeschlüsselt. Diese werden im Laufe der Arbeit näher beschrieben. Die Untersuchungen werden mit den Programmen *MATLAB* und *python* durchgeführt. Dabei wird ein bestehendes MATLAB-Modell eines 48 V-Hybriden verwendet, welches auch die Implementierung einer sogenannten *Offline-ECMS* beinhaltet [För24]. Außerdem wird die *Generic Dynamic Programming*-Funktion (*dpm-function*) der ETH Zürich für die Untersuchungen herangezogen [Sun09]. Darüber hinaus kommt die *Discrete-Time Markov Chain*-Funktion (*dtmc-function*) aus der *Econometrics Toolbox* von MATLAB zum Einsatz. Untersuchungen zum Maschinellen Lernen werden in *python* durchgeführt. Dies erfolgt mittels der Toolboxes *Keras/Tensorflow*, *Numpy*, *Scipy* und *Matplotlib*.

Es sei abschließend darauf hingewiesen, dass im Themenfeld der hybridelektrischen Fahrzeuge bereits seit über zwei Jahrzehnten intensiv geforscht wird. Der wissenschaftliche Beitrag dieser Arbeit besteht darin, die Anwendbarkeit vorhandener Konzepte zu analysieren und dafür geeignete Schnittstellen zu definieren sowie das Forschungsfeld an geeigneter Stelle durch neue, generisch einsetzbare Methodiken zu ergänzen. Mittels der erarbeiteten Werkzeuge erfolgen tiefergehende Untersuchungen für den Anwendungsfall eines 48 V-Systems unter realen Betriebsbedingungen, um hiervon neues Wissen abzuleiten.

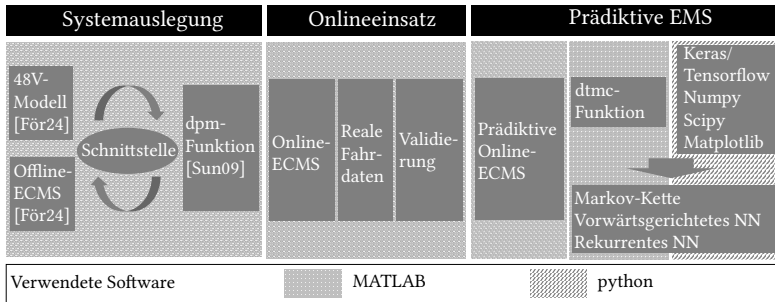


Abbildung 1.2: Übersicht über die drei vorgestellten Forschungsfelder mit Fokus auf die verwendete Software sowie die Einbindung vorhandener Modelle und Toolboxes.

Zur besseren Lesbarkeit wird durchgehend die männliche Form verwendet. Um die Verständlichkeit und die Einordnung der Begrifflichkeiten zu verbessern, werden - neben der jeweiligen deutschen Bezeichnung - zusätzlich international anerkannte Bezeichnungen (beispielsweise aus dem Bereich des Maschinellen Lernens) eingeführt. Darüber hinaus sei erwähnt, dass sowohl in der Anwendung der numerischen Lösungsverfahren als auch bei einer späteren Applikation im Fahrzeug eine Diskretisierung der Größen notwendig ist. Sämtliche Betrachtungen erfolgen daher in diskretisierter Zeit. Zur besseren Lesbarkeit wird jedoch überwiegend auf den diskreten Zeitindex k verzichtet. Auch die Abhängigkeiten der Variablen werden nur explizit angegeben, wenn dies dem Verständnis der Arbeit dienlich ist. Es sei außerdem erwähnt, dass der Kraftstoffbedarf und die CO_2 -Emissionen eines Kraftfahrzeugs über einen festen Proportionalitätsfaktor miteinander gekoppelt sind und in ihrer Aussagekraft hinsichtlich Kraftstoffeffizienz äquivalent zu betrachten sind. Zur besseren Unterscheidung von Fremdliteratur und eigener Literatur werden eigene Arbeiten durchnummeriert mit eckigen Klammern gelistet (z. B. [5]). Bei betreuten, studentischen Arbeiten ist zusätzlich der Präfix *S* enthalten (z. B. [S5]). Die in dieser Arbeit dargestellten Daten und Ergebnisse umfassen teilweise unternehmensinterne, wettbewerbsrelevante Inhalte. Daher wird im Rahmen der Arbeit stellenweise auf eine normierte Darstellung zurückgegriffen.

2 **Hybridelektrische Fahrzeuge (48 V-System)**

In diesem Kapitel werden die allgemeinen Grundlagen für hybridelektrische Fahrzeuge eingeführt. Diese umfassen zunächst die relevanten Topologien hybridelektrischer Fahrzeuge, mögliche Betriebsarten und den Begriff des Hybridisierungsgrads (Kapitel 2.1). In Kapitel 2.2 werden anschließend die wichtigsten Eigenschaften eines 48 V-Systems aufgezeigt. Danach wird auf die Systemmodellierung eingegangen (Kapitel 2.3), wobei zunächst die Modellierung des verwendeten Antriebsstrangs vorgestellt wird und danach die verwendeten Fahrzyklen zur Abbildung realer Betriebsbedingungen eingeführt werden.

2.1 **Topologien, Betriebsarten und Hybridisierungsgrad**

Entsprechend [Gör16] lassen sich hybridelektrische Fahrzeug in serielle, parallele und leistungsverzweigte Hybride unterteilen. Leistungsverzweigte Hybride erfordern grundsätzliche Änderungen im konventionellen Antriebsstrang und stehen im Widerspruch zur einfachen Systemintegration. Serielle Hybride sind durch die Leistungsgrenzen der 48 V-Technik in Kraftfahrzeugen nicht umsetzbar [För21]. Höhere Ströme würden größere Kabelquerschnitte verlangen, die im Widerspruch zur hinsichtlich CO₂-Reduktion möglichst geringen Fahrzeugmasse stehen. Die Untersuchungen beschränken sich daher auf Parallelhybride, welche in Abbildung 2.1 dargestellt sind. Hierbei sind mit P0 bis P4 die Positionen der jeweiligen Elektromotoren eingezeichnet. Ebenso sind die Kupplungen K0 und K1 sowie die Verbrennungskraftmaschine (VKM), das Getriebe (GB) und das Differential (DT)

eingetragen (vgl. Deufel et al. [2]). Im Rahmen der Untersuchungen werden Topologien mit Elektromotoren in P1-, P2- und P4-Position sowie die Kombinationen P14 und P24 mit jeweils zwei Elektromotoren betrachtet.




Abbildung 2.1: HEV-Topologien in Parallelkonfiguration aus Deufel et al. [2].

Durch die Parallelanordnung der Elektromotoren (EM) ergeben sich verschiedene Betriebsmodi:

- Reiner VKM-Betrieb
- VKM-Lastpunktabsenkung (LPAb)
- Reiner EM-Betrieb
- Rekuperation mit EM
- VKM-Lastpunktanhebung (LPAn)
- Boost mit EM

HEVs lassen sich neben ihrer Topologie auch nach dem Hybridisierungsgrad einteilen [Gör16]. Die im Rahmen dieser Arbeit untersuchten 48 V-Systeme mit bis zu 30 kW zählen dabei zu den autarken Hybriden, wobei sie sich den sogenannten Mild- und Vollhybriden zuordnen lassen. Im nächsten Kapitel wird beschrieben, wie sich ein solches 48 V-System zusammensetzt und welche Wechselwirkungen bestehen.

2.2 Das 48 V-System

Wie bereits in Kapitel 1 erwähnt, wird ein 48 V-System entsprechend Abbildung 2.2 durch seine Komponenten, die gewählte Topologie und die EMS charakterisiert [Sil16b], wobei der Fokus dieser Arbeit auf Letzterem liegt. Dabei steht das 48 V-System in Wechselwirkungen mit dem Fahrzeug selbst, dem

Fahrer und der Fahrzeugumgebung. Das Fahrzeug übt über seinen Antriebsstrang bzw. das verbaute Bordnetz mechanische und elektrische Lasten auf das 48 V-System aus. Diese resultieren aus der Fahrzeuggeschwindigkeit, der Fahrzeugbeschleunigung, der Fahrbahnsteigung, den allgemeinen Umweltbedingungen (Witterung, Jahreszeit, Vorhandensein einer Ampel, ...) und den gewählten Verbrauchereinstellungen, welche sich aus einem Zusammenspiel von Fahrer und Umgebung ergeben. So berücksichtigt der Fahrer bei der Fahrzeugführung neben der Straßenführung selbst beispielsweise den Verkehr, die Straßen- und Sichtverhältnisse. Je nach Automatisierungsgrad des Fahrzeugs können auch Geschwindigkeitsregelsysteme einen Einfluss haben. Zur Umsetzung simulativer Untersuchungen zu EMS des 48 V-Systems liegt der Fokus auf der Modellbildung des Antriebsstrangs und der Vorgabe von Realfahrzyklen, welche die realen Betriebsbedingungen bestmöglich widerspiegeln (vgl. gestrichelte Markierung in Abbildung 2.2).

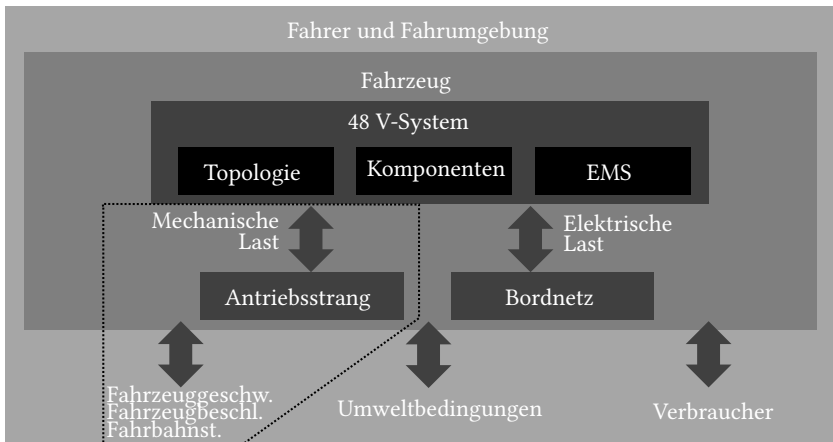


Abbildung 2.2: Wechselwirkungen des 48 V-Systems mit Fahrzeug, Fahrer und Fahrzeugumgebung in Anlehnung an [För21].

Nachfolgend wird die Systemmodellierung beschrieben. Dabei wird nach einer kurzen allgemeinen Einführung zu rückwärts- und vorwärtsrechnenden Simulationsmodellen auf die Modellierung des verwendeten Antriebsstrangs sowie die verwendeten Realfahrzyklen eingegangen.

2.3 Systemmodellierung

Wie bereits in Deufel et al. [2] beschrieben, wird im Bereich der Fahrzeugsimulation grundsätzlich zwischen rückwärts- und vorwärtsrechnenden Simulationsmodellen unterschieden. Vorwärtsrechende Modelle bilden die physikalische Kausalität des Systems ab: Mit Hilfe eines Fahrermodells (z. B. eines PID-Reglers) wird die gewünschte Fahrzeuggeschwindigkeit mit der tatsächlichen Fahrzeuggeschwindigkeit verglichen. Je nach Abweichung wird vom Fahrermodell ein entsprechendes Drehmoment gestellt, welches zu einer Fahrzeugbeschleunigung oder Verzögerung führt. Durch Integration ergibt sich eine neue Fahrzeuggeschwindigkeit. Im Gegensatz dazu wird bei einem rückwärtsrechnenden Modell davon ausgegangen, dass das Fahrzeug einem vordefinierten Fahrzeuggeschwindigkeits- und Fahrzeugbeschleunigungsprofil folgt. Es wird also kein Fahrermodell benötigt. Zwar stellt dies eine Vergleichbarkeit der Ergebnisse sicher, die Leistungsgrenzen des Antriebsstrangs (beispielsweise bei der Simulation der maximalen Fahrzeugbeschleunigung) können jedoch nur eingeschränkt berücksichtigt werden. Für eine detaillierte Darstellung der Vor- und Nachteile sei auf [Guz13, Obe15, Ono16, Wei18] verwiesen. Nachfolgend wird zunächst auf die Modellierung des exemplarisch verwendeten, hybridelektrischen Antriebsstrangs eingegangen, wobei dies auch die Komponenten des 48 V-Systems - den Elektromotor inkl. Leistungselektronik sowie die Batterie - umfasst. Obgleich die Untersuchungen an dem spezifischen, nachfolgend beschriebenen Fahrzeug durchgeführt werden, lassen sich die Erkenntnisse grundsätzlich auch auf andere Antriebsstränge übertragen. In diesem Zuge wird zur späteren Validierung ein Fahrzeug mit einem alternativen Antriebsstrang herangezogen (Kapitel 5.2).

2.3.1 Modellierung des hybridelektrischen Antriebsstrangs

Im Rahmen der Arbeit erfolgen lediglich Effizienzbetrachtungen ohne Untersuchungen im Grenzbereich des Antriebsstrangs. Daher wird für eine

bestmögliche Vergleichbarkeit der Ergebnisse ein rückwärtsrechnendes Modell gewählt. Gestützt wird diese Entscheidung dadurch, dass hiermit alle in Kapitel 3 identifizierten und für die Untersuchungen relevanten Optimierungsverfahren verwendet werden können. Da [Wei18] zudem nachweist, dass die Ergebnisse eines rückwärtsrechnenden Modells nahezu äquivalent zu einem vorwärtsrechnenden Modell sind, wird auf die Realisierung eines vorwärtsrechnenden Modells verzichtet. Bei einem rückwärtsrechnenden Modell muss für jeden Zeitpunkt der notwendige Drehmomentbedarf durch verschiedene Komponenten gestellt werden, wobei von der EMS das optimale Zusammenspiel gefunden werden muss. Dies umfasst beim untersuchten 48 V-System den Verbrennungsmotor (positives oder negatives Drehmoment), bis zu zwei Elektromotoren (jeweils positives oder negatives Drehmoment) und die mechanische Bremse (negatives Drehmoment). Für jede untersuchte Steuerung müssen die jeweiligen Drehmomente bestimmt werden. Dabei werden neben den jeweiligen Komponentengrenzen auch die zwischen den einzelnen Komponenten auftretenden Verluste berücksichtigt. Die vorliegende Arbeit baut auf dem Modell von [För24] auf, welches ein Fahrzeugmodell gekoppelt mit einer Offline-ECMS (vgl. Kapitel 3) beinhaltet und im Rahmen seiner Arbeiten bereits validiert wurde. Die wichtigsten Komponenten werden nachfolgend kurz erläutert.

Längsdynamik

Das Drehmoment an der Kurbelwelle (KW) ergibt sich aus der Längsdynamik des Fahrzeugs unter Berücksichtigung des dynamischen Radhalbmessers sowie der Übersetzungsverhältnisse des Fahrzeugs. Die bekannten Formeln aus der Fahrzeugdynamik sind nachfolgend dargestellt (Formeln 2.1-2.5). Die Fahrwiderstandskraft am Rad F_{wheel} ergibt sich als Summe aus der Luftwiderstandskraft F_{air} , der Rollwiderstandskraft F_{roll} , der Beschleunigungswiderstandskraft F_{acc} sowie der Steigungswiderstandskraft F_{α} . Für F_{air} ist der Luftwiderstandsbeiwert c_w , die projizierte Querschnittfläche des Fahrzeugs A , die Luftdichte ρ sowie die Fahrzeuggeschwindigkeit v relevant. F_{roll} setzt sich aus der Fahrzeugmasse m , der Erdbeschleunigung g , der Fahrbahnsteigung α sowie dem Rollwiderstandsbeiwert f_r zusammen.

Für F_{acc} wird die Fahrzeugmasse m sowie die Fahrzeugbeschleunigung a benötigt. F_{α} ergibt sich aus der Fahrzeugmasse m , der Erdbeschleunigung g sowie der Fahrbahnsteigung α :

$$F_{wheel} = F_{air} + F_{roll} + F_{acc} + F_{\alpha} \quad (2.1)$$

$$F_{air} = c_w \cdot A \cdot \frac{\rho}{2} \cdot v^2 \quad (2.2)$$

$$F_{roll} = m \cdot g \cdot \cos\alpha \cdot f_r \quad (2.3)$$

$$F_{acc} = m \cdot a \quad (2.4)$$

$$F_{\alpha} = m \cdot g \cdot \sin\alpha \quad (2.5)$$

Kraftfahrzeuge lassen sich nach dem deutschen Kraftfahrtbundesamt (KBA) bzw. der Europäischen Kommission in verschiedene Segmente einteilen [Eur02], welche sich hinsichtlich ihrer längsdynamischen Eigenschaften unterscheiden. Hiermit gehen auch verschiedene Antriebsleistungen einher. Eine Übersicht hierzu gibt Tabelle 2.1.

Tabelle 2.1: Fahrzeugsegmente für Personenkraftwagen entsprechend der Europäischen Kommission und dem deutschen Kraftfahrt-Bundesamt (Auswahl).

EU-Kommission	Beispiele	KBA	Beispiele
A: Kleinstwagen	Smart	Minis (Kleinstwagen)	VW up!
B: Kleinwagen	Ford Fiesta	Kleinwagen	VW Polo
C: Mittelklasse	VW Golf	Kompaktklasse	VW Golf
D: Obere Mittelklasse	Volvo S60	Mittelklasse	VW Passat
E: Oberklasse	BMW 5er	Obere Mittelklasse	Audi A6
F: Luxusklasse	BMW 7er	Oberklasse	Audi A8

In Anlehnung an [För21] werden die Untersuchungen exemplarisch an einem D-Segment Fahrzeug durchgeführt. Die zugehörigen Parameter und ihre entsprechenden Einheiten sind in Tabelle 2.2 aufgeführt.

Auf die Verwendung des verbreiteten Drehmassenzuschlagfaktors λ wird im Modell von [För24] verzichtet. Stattdessen werden die rotatorischen Massen in Abhängigkeit der Kupplung (offen/geschlossen) und der gewählten Getriebestufe explizit berücksichtigt.

Tabelle 2.2: Parameter des verwendeten D-Segment Fahrzeugs.

Luftwiderstandsbeiwert	c_w	0.26
Projizierte Querschnittfläche	A	2.23 m^2
Luftdichte	ρ	1.20 kg/m^3
Fahrzeugmasse	m	1580 kg
Erdbeschleunigung	g	9.81 m/s^2
Rollwiderstandsbeiwert	f_r	0.01

Getriebe

Das verwendete D-Segment Fahrzeug besitzt ein 9-Gang-Automatikgetriebe. Die EMS bestimmt die Drehmomentaufteilung zwischen dem/den EM und der VKM basierend auf dem Kurbelwellendrehmoment T_{CS} . Dafür müssen neben den Übersetzungen die Getriebeverlustmomente $T_{GB,loss}$ bekannt sein (Abbildung 2.3, links). Die Gangwahl erfolgt entsprechend den Schaltkennlinien (Abbildung 2.3, rechts). Im linken Teil von Abbildung 2.3 sind die Verlustmomente im Getriebe $T_{GB,loss}$ über der Kurbelwellendrehzahl n_{CS} für alle neun Gänge und Kurbelwellenmomente T_{CS} im Bereich 0 Nm bis 300 Nm dargestellt. Insgesamt ist eine Zunahme der Getriebeverluste bei Erhöhung der Kurbelwellendrehzahl und des Kurbelwellendrehmoments festzustellen.

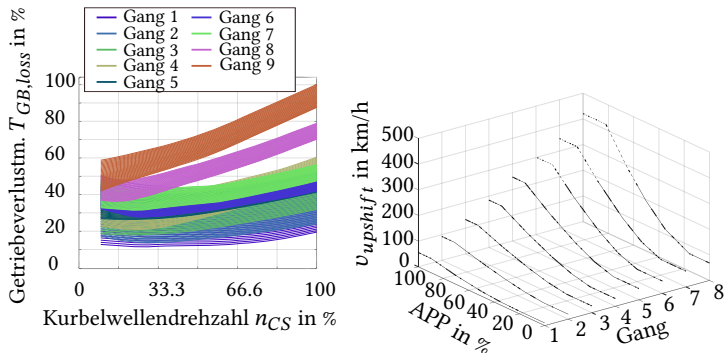


Abbildung 2.3: Getriebeverluste $T_{GB,loss}$ in Nm für Kurbelwellendrehmomente $T_{CS} = 0 \dots 300$ Nm dargestellt über der Kurbelwellendrehzahl n_{CS} . Jeweils für alle Gänge inklusive DT (links). Hochschaltgeschwindigkeiten $v_{upshift}$ für die Gänge 1-8 in Abhängigkeit der Fahrpedalstellung APP (rechts). Hochschaltgeschwindigkeiten $> 250 \text{ km/h}$ sind gestrichelt dargestellt. Die Achsen sind teilweise normiert dargestellt. Der Wert 100 % entspricht dem maximalen Getriebeverlustmoment bzw. der maximalen Kurbelwellendrehzahl in der Darstellung.

Darüber hinaus ist im rechten Teil von Abbildung 2.3, die Hochschaltgeschwindigkeit $v_{upshift}$ - also die Grenzggeschwindigkeit ab der hochgeschaltet wird - in Abhängigkeit der Fahrpedalstellung APP für jeden Gang definiert. Es ist deutlich zu sehen, dass stets bei höheren Fahrzeuggeschwindigkeiten hochgeschaltet wird, wenn die Fahrpedalstellung APP zunimmt. Bei Volllast (APP = 100 %) werden die Gänge für eine größtmögliche Drehmomentreserve maximal ausgefahren. Dies gilt für alle acht Gänge. Die Kennlinien für das Herunterschalten sind im Modell analog hinterlegt.

Verbrennungskraftmaschine

Die Wirkungsgrade der VKM (η_{ICE}) sind in Kennfeldern in Abhängigkeit von der Drehzahl der VKM (n_{ICE}) und des Drehmoments der VKM (T_{ICE}) hinterlegt. Wie im linken Teil von Abbildung 2.4 zu erkennen, liegt der Wirkungsgrad über weite Teile des Kennfelds bei $\eta_{ICE} > 30$ %. Lediglich bei niedrigen Lasten treten geringere Wirkungsgrade auf. Im rechten Teil von Abbildung 2.4 sind darüber hinaus Schleppmoment ($T_{ICE,drag}$) und Schleppleistung der VKM ($P_{ICE,drag}$) über der Drehzahl der VKM hinterlegt.

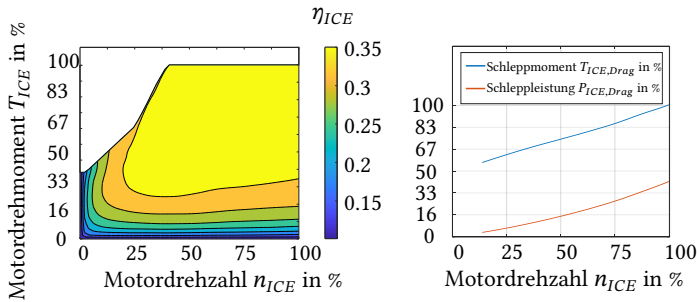


Abbildung 2.4: Stationäres Verbrennungsmotorkennfeld (links). Schleppleistung und Schleppmoment der VKM (rechts). Die Achsen sind teilweise normiert dargestellt. Der Wert 100 % entspricht dem maximalen Motordrehmoment (links) und dem maximalen Schleppmoment (rechts) in der Darstellung. Ebenso entspricht 100 % jeweils der maximal dargestellten Motordrehzahl.

Durch die Verwendung des stationären Kennfelds werden dynamische Effekte wie beispielsweise das Drehmomentanstiegsverhalten analog zu [Ueb14] nicht berücksichtigt.

Elektromotor und Leistungselektronik

Die Wirkungsgrade von Elektromotor (EM) und Leistungselektronik (LE) der verbauten permanentenerregten Synchronmaschine sind in den spannungsabhängigen Wirkungsgraden des EM (η_{EM}) in Abhängigkeit von der Drehzahl des EM (n_{EM}) und des Drehmoments des EM (T_{EM}) zusammengefasst. Hierbei ist die Übersetzung, mit welcher der EM an die Kurbelwelle (KW) angebracht ist, bereits berücksichtigt. Wie in Abbildung 2.5 zu sehen, steigt mit höherer Spannung auch die Eckdrehzahl an und es treten höhere Wirkungsgrade auf.




Abbildung 2.5: Elektromotorkennfeld (inkl. Leistungselektronik) für eine Spannung von 40 V (links) und 52 V (rechts) mit einer maximalen Leistung von 15 kW. Die Achsen sind teilweise normiert dargestellt. Der Wert 100 % entspricht dem maximalen Motordrehmoment bzw. der maximalen Motordrehzahl in der Darstellung.

Batterie

Die Modellierung einer Batterie (BAT) kann auf verschiedene Art und Weisen erfolgen. Einen Überblick über verschiedene Modellierungsansätze bietet beispielsweise [Alh16]. Im Rahmen der Arbeit wird für die verbaute Batterie mit Nickel-Mangan-Kobalt/Graphit-Zellen das verbreitete, einfache Ersatzschaltbild bestehend aus Leerlaufspannung U_{OCV} , innerem Widerstand R_i und Klemmenspannung U_{bat} verwendet (Abbildung 2.6). Der Einfluss der Temperatur wird hierbei nicht berücksichtigt.




Abbildung 2.6: Einfaches Ersatzschaltbild der Batterie.

Über die Maschenregel lässt sich hieraus der Zusammenhang zwischen der Leerlaufspannung U_{OCV} , dem inneren Widerstand R_i , der Klemmenleistung P_{bat} und dem Batteriestrom I_{bat} herleiten (Formel 2.6):

$$I_{bat} = \frac{U_{OCV}}{2R_i} - \sqrt{\left(\frac{U_{OCV}}{2R_i}\right)^2 - \frac{P_{bat}}{R_i}} \quad (2.6)$$

Die Leerlaufspannung und der innere Widerstand sind in Abhängigkeit des Batterieladezustands (engl. *State-Of-Charge*, kurz SOC) sowohl für Entladen wie auch für Laden hinterlegt. Die entsprechenden Kennfelder sind in Abbildung 4.1 dargestellt. Für die Klemmenspannung gilt (Formel 2.7):

$$U_{bat} = U_{OCV} - R_i \cdot I_{bat} \quad (2.7)$$

Unter Berücksichtigung von Formel 2.7 ergibt sich für die Änderung des Batterieladezustands $dSOC$ (Formel 2.8):

$$dSOC = -\frac{\frac{P_{bat}}{U_{bat}} \cdot dt}{C} \cdot 100 \quad (2.8)$$

Für die Verlustleistung $P_{bat,loss}$ ergibt sich (Formel 2.9):

$$P_{bat,loss} = R_i \cdot \left(\frac{P_{bat}}{U_{bat}}\right)^2 \quad (2.9)$$

Die Energieänderung dE_{bat} in der Batterie lässt sich nach Formel 2.10 bestimmen:

$$dE_{bat} = -(P_{bat} + P_{bat,loss}) \cdot dt \quad (2.10)$$

Für nähere Informationen sei auf [Ono16] verwiesen.

Insgesamt basiert das Modell auf einigen, in der Modellbildung gängigen Vereinfachungen, wodurch beim Vergleich mit Messwerten im Rahmen von Kapitel 5.2 Abweichungen zu erwarten sind.

- Der dynamische Radhalbmesser ist geschwindigkeits- und fahrzeugmasseabhängig. Im Modell wurde ein konstanter dynamischer Radhalbmesser r_{dyn} angenommen.
- Beim Reifen tritt im Traktions- bzw. Bremsfall ein Schlupf zur Fahrbahn auf. Dieser wird bei der Modellierung nicht berücksichtigt. Dies umfasst auch den individuellen Radschlupf im Falle eines Allradantriebs.
- Für den Aufbau von Seitenkräften muss der Reifen unter einem Schräglaufwinkel laufen. Hierdurch ergibt sich auch eine Kraftkomponente entgegen der Fahrgeschwindigkeit. Dieser sogenannte Kurvenfahrwiderstand wird nicht berücksichtigt.
- Der Kraftstoffbedarf für einen VKM-Start wird im Modell aufgrund der großen Schwankungen nicht berücksichtigt (Siehe hierzu Abschnitt 4.3.1).
- Es wird eine Fahrt bei Windstille angenommen. D. h. der Luftwiderstand ergibt sich nur aus der Verdrängung der vorhandenen Luftmasse, wobei die Relativgeschwindigkeit exakt der Fahrzeuggeschwindigkeit v entspricht. Hierbei wird ein konstanter Luftwiderstandsbeiwert c_w und eine konstante Luftangriffsfläche A angenommen.
- Der zum Betrieb der Nebenverbraucher notwendige Energiebedarf wird als Konstante berücksichtigt. Dabei wird davon ausgegangen, dass die Spitzen eines kontinuierlichen Lastprofils im Vergleich zu einer konstanten, gemittelten Last keinen wesentlichen Einfluss auf das Verhalten des 48 V-Systems haben, siehe hierzu auch [För24].
- Temperatureinflüsse werden im Modell nicht berücksichtigt.

- Das Bremsen durch Rekuperation wird nur vereinfacht abgebildet. Dabei wird die rekuperierbare Energie mithilfe einer entsprechenden Logik unter Berücksichtigung der Grenzen der elektrischen Komponenten und des Einsatzes der mechanischen Bremse ermittelt.

Nachdem die wichtigsten Komponenten des Antriebsstrangs sowie die getroffenen Vereinfachungen eingeführt wurden, werden nun die verwendeten Fahrzyklen vorgestellt.

2.3.2 Realfahrzyklen

Um reale Betriebsbedingungen bestmöglich abzubilden, werden die von [För21] entwickelten Realfahrzyklen verwendet. Diese bilden die statistische Gesamtheit von über 1 000 000 km realem Fahrbetrieb in insgesamt zwölf Realfahrzyklen ab, vgl. Deufel et al. [2]. Dabei sind jegliche Nutzungsszenarien wie eine Fahrt im Sommer und im Winter, eine Fahrt auf gerader Strecke und auf kurviger Straße und auch das gesamte Fahrerspektrum von einem sportlichen bis zu einem defensiven Fahrer abgedeckt. Selbst Sonderfälle wie das Beschleunigen am Berg bei maximaler Steigfähigkeit, eine Volllastbeschleunigung von 0-100 km/h oder ein Zwischenspurt von 80 auf 120 km/h sind entsprechend ihrem Auftreten im realen Fahrbetrieb enthalten. Die Fahrzyklen sind nachfolgend dargestellt (Abbildung 2.7), wobei auf eine Darstellung der zugehörigen Fahrbahnsteigungen verzichtet wird. Es wird zwischen drei Fahrertypen sowie vier Fahrumgebungen unterschieden. Die Fahrzyklen werden entsprechend der nachfolgenden Zuordnung von 1-12 durchnummeriert.

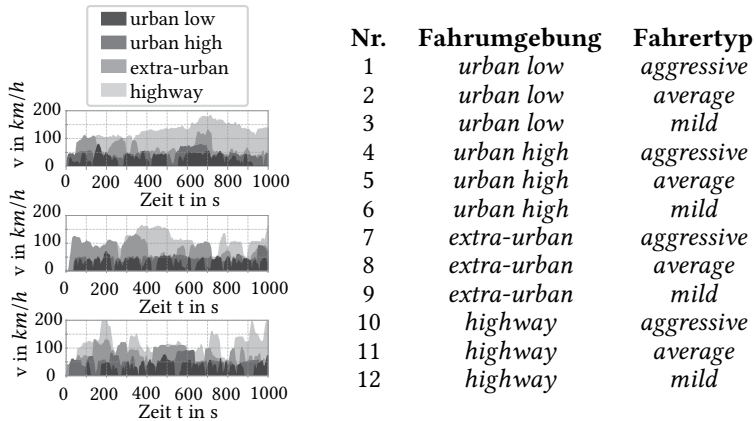


Abbildung 2.7: Links: Verwendete zwölf Realfahrzyklen, sortiert nach drei Fahrerarten: *aggressive* (oben), *average* (mitte), *mild* (unten) aus [För21]. Jeweils für vier verschiedene Fahrumgebungen dargestellt. Rechts: Nummerierung der zwölf Realfahrzyklen.

Neben den vorgestellten zwölf Realfahrzyklen wird für die Validierung der entwickelten Online-ECMS (Kapitel 5) sowie die abschließenden Potentialanalysen prädiktiver EMS (Kapitel 6) auf zwei weitere Datensätze zurückgegriffen:

- Die zur Validierung verwendeten Dauerläuferdaten werden dabei als *Datensatz zur Validierung* (vgl. Kapitel 5.2.1 bzw. Anhang G) bezeichnet. Zwar bilden diese nicht die statistische Gesamtheit von 1 000 000 km ab, die Messungen enthalten jedoch neben den gefahrenen Geschwindigkeitsprofilen wichtige Systemgrößen, um eine umfassende Validierung der entwickelten EMS zu ermöglichen.
- Der *Datensatz zur Validierung* enthält wichtige Systemgrößen, allerdings sind keine GNSS (Global Navigation Satellite System)-Positionen hinterlegt, um die Fahrzyklen um Kartendaten anzureichern. Für die Potentialanalysen prädiktiver EMS wird daher ein weiterer Datensatz herangezogen, der in Anhang H vorgestellt und entsprechend Anhang I aufbereitet wurde. Dieser wird als *Alternativer Datensatz* bezeichnet (Kapitel 6).

Nachdem die wichtigsten Komponenten des Antriebsstrangs und die verwendeten Realfahrzyklen vorgestellt wurden, soll nun ein Zwischenfazit zur Systemmodellierung gezogen werden.

2.3.3 Zwischenfazit Systemmodellierung

In diesem Kapitel wurde die Modellierung des verwendeten, hybridelektrischen Antriebsstrangs beschrieben. Wie bereits erwähnt, wurde das Modell in der Arbeit von [För24] eingesetzt und validiert. Zwar erhebt die Arbeit den Anspruch an Untersuchungen unter realen Betriebsbedingungen, die Realität lässt sich jedoch in der Simulation aufgrund der notwendigen Modellbildung stets nur eingeschränkt abbilden: Es wird ein rückwärtsrechendes Simulationsmodell verwendet. Das Längsdynamikmodell basiert auf den gängigen Fahrwiderstandsgleichungen. Das Getriebemodell umfasst neben einem Kennfeld der Getriebeverluste die Schaltstrategie. Darüber sind VKM und EM über jeweils ein stationäres Kennfeld dargestellt. Die Eigenschaften des EM sind spannungsabhängig. Darüber hinaus wird ein einfaches Ersatzschaltbild der Batterie, bestehend aus Leerlaufspannung und innerem Widerstand verwendet. Die Batterieeigenschaften sind in Abhängigkeit des Batterieladezustands hinterlegt. Es gilt an dieser Stelle kritisch festzuhalten, dass auf detaillierte Betrachtungen wie die Abbildung der Nebenverbraucher über Lastkurven, die Berücksichtigung von Betriebstemperaturen oder eine genauere Betrachtung von Kurvenfahrten verzichtet wird. Der Anspruch an Untersuchungen unter realen Betriebsbedingungen beschränkt sich in dieser Arbeit auf die Verwendung von Realfahrzyklen. Durch die getroffenen Vereinfachungen, sind Abweichungen beim Vergleich mit realen Fahrdaten zu erwarten. Die verwendeten zwölf Realfahrzyklen wurden anschließend vorgestellt, wobei gezeigt wird, dass die Untersuchungen mangels Datenverfügbarkeit nicht durchgehend mit einem Datensatz durchgeführt werden. So kommen für die Validierung der entwickelten Online-ECMS und die späteren Potentialanalysen prädiktiver EMS zwei weitere Datensätze zum Einsatz, die jedoch erst im späteren Verlauf der Arbeit eingeführt werden (Kapitel 5 und Kapitel 6).

3 **Energiemanagement elektrifizierter Fahrzeugantriebe**

In diesem Kapitel wird ein Überblick über den Stand der Forschung im Bereich des Energiemanagements elektrifizierter Fahrzeugantriebe gegeben. Hierbei werden zum einen die notwendigen Grundlagen eingeführt, auf denen die im Rahmen der Arbeit erarbeiteten Methodiken basieren. Zum anderen wird der Forschungsbedarf zur Beantwortung der bereits in Kapitel 1.2 vorgestellten Forschungsfragen untermauert. Dabei wird zunächst eine allgemeine Übersicht zu Energiemanagementstrategien gegeben (Kapitel 3.1). Anschließend werden die DP (Kapitel 3.2), das PMP und die ECMS (Kapitel 3.3), welche den Fokus dieser Arbeit darstellen, detailliert eingeführt. Prädiktive EMS werden in Kapitel 3.4 gesondert behandelt. Entsprechend den Ausführungen in Kapitel 1.2 wird im Rahmen der Arbeit unter einer Prädiktion eine Vorhersage der vorausliegenden Gegebenheiten im laufenden Fahrbetrieb verstanden. Dabei ist durch die Kenntnis des zukünftigen Fahrprofils über einen begrenzten Zeithorizont für EMS aus dem Bereich der Offlineoptimierung ein Onlineeinsatz möglich. So kann beispielsweise eine DP online eingesetzt werden, wobei durch einen entsprechend begrenzten Zeithorizont in Verbindung mit recheneffizienten Algorithmen ein Einsatz im fahrenden Fahrzeug möglich ist. Ebenso können onlinefähige EMS durch die Berücksichtigung zusätzlicher Informationen verbessert werden. Entsprechend den Ausführungen in Kapitel 1.2 kann eine onlinefähige EMS also prädizierte Informationen mitberücksichtigen, jedoch wird eine Prädiktion zukünftiger Informationen im Rahmen dieser Arbeit als nicht zwingend erforderlich für einen Onlinebetrieb angesehen. Hinsichtlich einer prädiktiven EMS wird zunächst der Grundgedanke einer Modellprädiktiven Regelung im Allgemeinen beschrieben. Anschließend wird aufgezeigt, mit welchen Verfahren die hierfür notwendigen

Prädiktionen erfolgen können. In einem weiteren Kapitel wird beschrieben, wie entsprechende Prädiktionen im Rahmen prädiktiver EMS letztlich verwendet werden können. Wie bereits in Kapitel 1.2 beschrieben, werden im Rahmen der Arbeit die Prädiktion und der Optimierer getrennt voneinander betrachtet. Bei der Offline-Systemauslegung hingegen erübrigt sich die Herausforderung einer Vorhersage im laufenden Fahrbetrieb grundsätzlich. Hier ist das gesamte Fahrgeschwindigkeitsprofil bekannt. Darüber hinaus sei erwähnt, dass sich Optimierungsprobleme im Rahmen der Arbeit weiterhin auf die optimierte Nutzung von VKM und EM beschränken. Eine Optimierung des zugrunde liegenden Geschwindigkeitsverlaufs selbst entfällt, da im Fokus der Arbeit die Untersuchung realer, durch einen Fahrer vorgegebener Fahrgeschwindigkeitsprofile steht.

3.1 Übersicht Energiemanagementstrategien (EMS)

Wie bereits in Deufel et al. [2] beschrieben, werden EMS für elektrifizierte Fahrzeugantriebe seit rund zwei Jahrzehnten intensiv erforscht. Für einen Gesamtüberblick über bestehende Arbeiten sei auf [Sal07, Ser09a, Riz15, Ono16, Sil16b, Jia17, Xu19, Tra20] verwiesen. Grundsätzlich gibt es für die Unterteilung der Strategien verschiedene Ansätze. Eine Möglichkeit ist es, EMS in regelbasierte, optimierungsbasierte und lernbasierte Methoden aufzuteilen [Hu18, Tra20, Qi22]. Es existieren jedoch auch Mischformen. Des Weiteren kann zwischen Offline- und Onlinestrategien unterschieden werden [Cha11, Bal15, Tra20]: Offlinestrategien zeichnen sich dadurch aus, dass das gesamte Fahrgeschwindigkeitsprofil im Voraus bekannt sein muss, um hiervon für eine spezifische Hybridarchitektur das theoretische Optimum zu ermitteln. Dieses kann beispielsweise der unter den gegebenen Randbedingungen geringste notwendige Kraftstoffbedarf darstellen, welcher sich bei einem optimalen Betrieb der Antriebsmaschinen ergibt. Somit kann eine spezifische Hybridarchitektur hinsichtlich ihrer Einsparpotentiale eingestuft werden. Ebenso können die Ergebnisse als Vergleichsbasis dienen, um onlinefähige Konzepte für den Einsatz im realen Fahrbetrieb zu bewerten.

Bei Onlinestrategien ist dagegen keines oder nur begrenztes a-priori-Wissen über die Zukunft notwendig. Onlinestrategien erlauben somit einen Einsatz im Fahrzeug. Die vorliegende Arbeit untersucht die Anwendbarkeit von EMS auf 48 V-Systeme sowohl in der Online- wie auch in der Offline-Anwendung.

Regelbasierte Methoden werden nicht näher untersucht, da diese in der Regel auf heuristischen Ansätzen beruhen und somit kein optimales Verhalten gewährleisten. Darüber hinaus müssen diese fahrzeugspezifisch konfiguriert werden und sind daher für eine Anwendung auf verschiedene Topologien ungeeignet.

Zu den **Lernbasierten** Methoden gehört das sogenannte Bestärkende Lernen, welches auch als *Reinforcement Learning* (RL) bezeichnet wird. Bei diesem Ansatz kann der optimale Betrieb online im Fahrzeug im Rahmen eines selbstlernenden Prozesses eigenständig durch den sogenannten Agenten gefunden werden. Das Funktionsprinzip ist in Abbildung 3.1 dargestellt.




Abbildung 3.1: Prinzipskizze zum Bestärkenden Lernen, *Reinforcement Learning* (RL). Basierend auf [Sut15, Agg18, Mat23].

Die *Strategie* weist jedem Zustand eine optimale Aktion zu. Dies kann tabellarisch erfolgen oder durch Künstliche Neuronale Netze (engl. *Artificial Neural Networks*, kurz ANN). Je nach gewählter Aktion (beispielsweise die Drehmomentaufteilung bei einem Parallelhybrid) ergibt sich ein neuer Zustand, der entsprechend aus der Umgebung an den Agenten zurückgegeben wird. Die Umgebung fasst das hybridelektrische Fahrzeug selbst, die eigentliche Fahrumgebung und den Fahrer - welcher die Fahraufgabe vorgibt - zusammen.

Darüber hinaus bewertet eine Belohnungsfunktion die Aktionen des Agenten entsprechend einer festgelegten Gewichtung: Beispielsweise hinsichtlich erzielttem Kraftstoffverbrauch oder Einhaltung eines ladungserhaltenden Betriebs (engl. *charge sustaining*, kurz CS genannt). Die entsprechende Belohnung wird dann an den Agenten zurückgeführt. Der *Lernalgorithmus* passt die Strategie anhand von Zuständen, Aktionen und Belohnungen laufend an. Verbreitete Verfahren sind das *Q-Learning* (hier werden die Belohnungen für die verschiedenen Zustände und Aktionen in einer Tabelle hinterlegt), das *Deep RL* (Verwendung eines ANN statt einer Tabelle) und das *Actor-Critic RL* (Realisierung kontinuierlicher Zustände und Aktionen mittels ANN). Das Verfahren des RL wurde bereits in einigen Forschungsarbeiten [Cao17, Kon17, Li17, Hu18, Wu19, Yin19, Guo20] angewandt. Im Rahmen der Voruntersuchungen werden entsprechende Algorithmen entwickelt und auf die Anwendbarkeit für Realfahrzyklen im Zusammenhang mit 48 V-Systemen untersucht. Neben einer direkten Steuerung der Drehmomentenverteilung wird eine weitere Variante untersucht, bei der nicht die Drehmomentenverteilung direkt, sondern der Äquivalenzfaktor einer ECMS (ECMS siehe Kapitel 3.3) durch den RL-Agenten gesteuert wird. Wie die Untersuchungen von [S2] und [S5] unabhängig voneinander zeigen, weisen die erzielten Kraftstoffverbräuche bei der Anwendung auf Realfahrzyklen durchweg Abweichungen zur optimalen Lösung im zweistelligen Prozentbereich auf. Tiefergehende Untersuchungen für optimales EMS im Onlinebetrieb mittels RL entfallen entsprechend im Rahmen der vorliegenden Arbeit.

Optimierungsbasierte Methoden bilden den Schwerpunkt dieser Arbeit, sowohl für den Online- als auch für den Offline-Bereich. Wie bereits in Deufel et al. [2] beschrieben, gilt die Dynamische Programmierung (DP) für die Bestimmung des Optimums im Bereich der Offlineoptimierung als konkurrenzlos, da sie abgesehen von den Fehlern, die sich aus der notwendigen Diskretisierung der Zustands- und Steuergrößen ergeben, stets global optimale Lösungen liefert. Allerdings erfordert sie einen hohen Rechenaufwand [Sun08, Sun09, Sun10, Elb13]. Neben der DP kann auch das Pontryagin'sche Minimum Prinzip (PMP) zur Bestimmung des globalen Optimums herangezogen werden. Für Vergleiche zwischen DP und PMP sei

auf [Kim11, Kim12] verwiesen (siehe auch Kapitel 3.3). Die ECMS, welche erstmals von Paganelli et al. [Pag02] veröffentlicht wurde, lässt sich aus dem PMP ableiten (siehe hierzu Kapitel 3.3). Je nach Implementierung wird die ECMS den Offline- oder Onlinestrategien zugeordnet. Aufgrund der Äquivalenz der ECMS zum PMP kann sie zur Bestimmung des globalen Optimums für zeitinvariante Systeme angewendet werden. In diesem Fall wird der sogenannte Äquivalenzfaktor iterativ bestimmt [Ser09b, Zhe14]. Insbesondere aufgrund des geringen Rechenaufwands wird diese sogenannte Offline-ECMS häufig zur Bestimmung des globalen Optimums in der Offlineoptimierung genutzt [Adh10, Cha11, Thi13, Sci14, Acc20, Don20, Sil22, Par22]. Für die Offline-Untersuchung von Topologien mit zwei EM wurde die 2D-ECMS entwickelt [May19].

Für eine onlinefähige Implementierung der ECMS wurde das Konzept einer SOC-abhängigen Regelung des Äquivalenzfaktors bereits mehrfach eingesetzt [Mus05, Kes08, Cha10, Ono10, Ono11, Siv12, Ena17, Fu17, Oud18, Zha18]. Andere onlinefähige Ansätze der ECMS basieren auf der Fahrererkennung [Gu06] oder Künstlichen Neuronalen Netzen (ANN) zur Bestimmung des Äquivalenzfaktors [Xie18a, Che21]. Zu diesen datengetriebenen Varianten lässt sich auch die im vorherigen Absatz erwähnte Kopplung mit RL zuordnen. Ebenso existieren Ansätze, die einen Fuzzy-Controller verwenden [Li14, Zha16a, Zha16b, Wan19]. Im Bezug auf die Verwendung prädiktiver Informationen wurde gezeigt, dass ein nicht prädiktives Online-ECMS-Konzept für Onlineanwendungen unter Berücksichtigung prädiktiver Informationen verbessert werden kann [Kur15]. Daneben gibt es auch prädiktive Online-ECMS-Ansätze, bei denen Vorhersagen für die Grundfunktionalität der ECMS zwingend erforderlich sind [Mus05, Gao17]. EMS, bei denen die optimale Regelung unter Berücksichtigung eines Vorhersagehorizonts ermittelt wird, werden allgemein als Modellprädiktive Regelung (engl. *Model Predictive Control*, kurz MPC) bezeichnet. Im Gegensatz zur beschriebenen Erweiterung einer ECMS um prädiktive Eigenschaften, kann die Steuerung dabei auch durch die Optimierung über einen prädierten Horizont bestimmt werden (Kapitel 3.4).

Dabei können grundsätzlich verschiedene Optimierer verwendet werden [Jos14, Hua17, Zho21]. So kommen beispielsweise approximierte Ansätze der DP (ADP) zum Einsatz. Durch den deutlich reduzierten Rechenaufwand kann eine Onlinefähigkeit der DP realisiert werden [Wah15, Bau19], vgl. Deufel et al. [2]. Hierzu wurde in [Wah15] der Vorausberechnungshorizont entsprechend an die zur Verfügung stehende Rechenzeit angepasst. Dabei wurde eine Kaskadierung mehrerer Optimierer mit fortwährender Neuberechnung realisiert, wobei die Steuerung des Fahrzeugs auf drei Vorausschauhorizonten von 50 ms, einigen Sekunden bis Minuten und eine lange Sicht gesteuert wird. Die Ermittlung einer global optimalen Lösung ist mit dem hier implementierten Algorithmus der DP nicht möglich. Entsprechende Untersuchungen zur Beschleunigung des Algorithmus der DP wurden im Rahmen des Forschungsprojekts durch [S10] angestellt. Sowohl in der Systemauslegung wie auch im Rahmen einer MPC können noch eine Vielzahl anderer Optimierungsverfahren verwendet werden. In dieser Hinsicht seien abschließend noch die Partikelschwarmoptimierung (PSO), der Genetische Algorithmus (GA), der Ameisenalgorithmus (ACO), die Lineare Programmierung, die quadratische Programmierung, die Sequentielle Quadratische Optimierung und die Konvexe Programmierung genannt. Entsprechende Voruntersuchungen hinsichtlich eines bewertenden Vergleichs und exemplarischen Umsetzungen wurden durch [S9] durchgeführt. Es konnte gezeigt werden, dass beispielsweise die Konvexe Optimierung eine erhebliche Verringerung der Rechenzeiten gegenüber der DP ermöglicht. Die hierfür notwendigen Vereinfachungen des Modells stehen jedoch im Widerspruch zum Anspruch nach einem hohen Detaillierungsgrad und werden daher nicht weiter verfolgt.

Nachdem nun ein Überblick zu Energiemanagementstrategien im Allgemeinen gegeben wurde, werden nachfolgend die DP (Kapitel 3.2), das PMP und die ECMS (Kapitel 3.3), welche den Fokus dieser Arbeit darstellen, detailliert eingeführt.

3.2 Dynamische Programmierung (DP)

Die Dynamische Programmierung (DP) eignet sich zur optimalen Steuerung nichtlinearer, zeitdiskreter, dynamischer Systeme und wurde im Bereich des Energiemanagements von HEV bereits vielfach eingesetzt [Sun14, Zen15, Li16, Qin17, Xie18a, Yan20]. Allgemein werden Probleme der optimalen Steuerung entsprechend Formel 3.1 formuliert. Dabei ergibt sich die Zustandsänderung \dot{x} als Funktion vom Zustand x , der Steuergröße u und der Zeit t [Sun09, Ono16]:

$$\dot{x} = f(x(t), u(t), t) \quad (3.1)$$

Hierbei steht $x(t) \in X(t) \subset \mathbb{R}^n$ für den Zustandsvektor und $u(t) \in U(t) \subset \mathbb{R}^m$ für den Steuerungsvektor. Die Startbedingungen werden mit Formel 3.2 und die Endbedingungen mit Formel 3.3 definiert. Dabei gibt x_0 den Initialwert von x an. $x_{f,min}$ steht für den zulässigen Minimalwert von x im finalen Zeitschritt t_f . $x_{f,max}$ gibt das entsprechende Maximum an [Sun09, Ono16]:

$$x(0) = x_0 \quad (3.2)$$

$$x(t_f) \in [x_{f,min}, x_{f,max}] \quad (3.3)$$

Die zu minimierende Kostenfunktion J wird entsprechend Formel 3.4 beschrieben. Hierbei repräsentiert $\phi(x(t_f))$ die Kosten im finalen Zeitschritt. $L(x(t), u(t), t)$ gibt die instantanen Kosten des Optimalsteuerungsproblems wieder [Sun09, Ono16]:

$$J = \phi(x(t_f)) + \int_0^{t_f} L(x(t), u(t), t) dt \quad (3.4)$$

Für die Anwendung der DP muss das Modell zunächst diskretisiert werden, sodass sich die Modellbeschreibung mit der Zustandsgröße $x_k \in X_k$ und der Steuergröße $u_k \in U_k$ nach Formel 3.5 ergibt.

Dabei steht x_{k+1} für den Zustand im nächsten Zeitschritt, welcher sich durch die diskretisierte Funktion f_k sowie dem Zustand im aktuellen Zeitschritt x_k und der Steuerung im aktuellen Zeitschritt u_k berechnet [Sun09, Ono16]:

$$x_{k+1} = f_k(x_k, u_k) \quad (3.5)$$

Die Kostenfunktion J für den Startzustand $x(0) = x_0$ lässt sich für die DP entsprechend Formel 3.6 wie nachfolgend formulieren. Hierbei steht $u = \{u_0, u_1, \dots, u_{N-1}\}$ für eine bestimmte Steuergrößenfolge. Analog zu Formel 3.4 repräsentiert der Term $L_N(x_N)$ die Kosten im finalen Zeitschritt N . Der Term $L_k(x_k, u_k)$ gibt weiterhin die instantanen Kosten der Steuerung u_k für den Zustand x_k wieder [Sun09, Ono16]:

$$J(x_0, u) = L_N(x_N) + \sum_{k=1}^{N-1} L_k(x_k, u_k) \quad (3.6)$$

Die optimale Steuerung $u^* = \{u_1^*, u_2^*, \dots, u_{N-1}^*\}$ minimiert J und kann somit nach [Sun09, Ono16] entsprechend Formel 3.7 beschrieben werden. Dabei gibt $J^*(x_0)$ die Kosten für die optimale Steuerung ausgehend vom Initialzustand x_0 an:

$$J^*(x_0) = \min_u J(x_0, u^*) \quad (3.7)$$

Die Formel 3.6 lässt sich nun für das Teilproblem vom Zeitpunkt $k = i$ und Zustand x_i bis zum Ende des Fahrzyklus umschreiben. Hierfür gilt die optimale Steuerung $\{u_i^*, u_{i+1}^*, \dots, u_{N-1}^*\}$. Damit ergeben sich die kumulierten Kosten bis zur Zielerreichung (engl. *Cost-To-Go*) Y entsprechend Formel 3.8 zu [Ono16]:

$$Y(x_i, i) = L_N(x_N) + \sum_{k=i}^{N-1} L_k(x_k, u_k) \quad (3.8)$$

Nach [Bel57] werden auf diese Weise nach Formel 3.9 die optimalen *Cost-To-Go* Y zum Zeitpunkt k für jeden Zustand im Rahmen eines Rückwärtslaufs sukzessive berechnet und in der Matrix der optimalen Steuergrößen μ^* gespeichert.

Dabei fasst Y_{k+1} stets die *Cost-To-Go* vom Folgezeitschritt $k+1$ bis an das Ende des Fahrzyklus zusammen. $L_k(x_k, u)$ gibt weiterhin die instantanen Kosten wieder [Ono16]:

$$u_k = \mu^*(x_k, k) = \min_{u_k \in U_k} (L_k(x_k, u) + Y_{k+1}(f_k(x_k, u_k)), u_k) \quad (3.9)$$

Eine typische Umsetzung der DP wie in [Sun09] umfasst einen Rückwärtslauf, gefolgt von einem anschließenden Vorwärtslauf. Im ersten Schritt des Rückwärtslaufs entspricht Y den finalen Kosten L_N . Im letzten Rechenschritt des Rückwärtslaufs entspricht Y den optimalen Gesamtkosten J^* . Dazwischen wird das Modell sukzessive auf alle Zeitschritte k des Fahrzyklus für die gewählten Zustands- und Steuergrößen angewandt. Da der hierbei vom Modell ausgegebene Zustand im nächsten Zeitschritt x_{k+1} , auch zwischen den diskretisierten Zuständen des Zustandsgitters liegen kann, welches sich durch die Auflösung des SOC im Zuge der Diskretisierung ergibt, muss zur Bestimmung von Y_k meist interpoliert werden. Die Interpolation erfolgt dabei auf Basis der zum Zeitschritt k bereits bekannten Werte von Y_{k+1} der Zustände des Zustandsgitters. Die im Rahmen dieses Rückwärtslaufs bestimmten optimalen Steuerungen μ^* für jeden Zeitschritt können abschließend in einem nachfolgenden Vorwärtslauf ausgehend vom Initialzustand angewandt werden. Die vom Modell ausgegebenen Zustände im Folgezeitschritt x_{k+1} müssen dabei weiterhin nicht zwingend auf dem Zustandsgitter liegen. Die erreichten Zustände x_{k+1} können dabei jedoch als x_k ohne weitere Interpolation im Folgezeitschritt berücksichtigt werden. Ein exemplarisches Anwendungsbeispiel ist in Anhang A aufgezeigt.

Beschreibt man die Anzahl der Zustände einer Zustandsgröße mit N_X und die Anzahl der Dimensionen (also die Anzahl an Zustandsgrößen) mit I , so ergeben sich insgesamt $(N_X)^I$ unterschiedliche Zustände. Bezeichnet man nun die Anzahl der Werte, die eine Steuergröße annehmen kann mit N_U und die Anzahl der Dimensionen (also die Anzahl an Steuergrößen) mit K , so ergeben sich insgesamt $(N_U)^K$ unterschiedliche Aktionen.

Unter Berücksichtigung der Anzahl der Stufen im Entscheidungsprozess, also der Länge des diskretisierten Fahrzyklus N_{Cycle} , lässt sich hinsichtlich des Rechenaufwands bei der Rückwärtsrechnung entsprechend Formel 3.10 vereinfacht schreiben [Wah15]:

$$O(N_{cycle} \cdot (N_X)^I \cdot (N_U)^K) \quad (3.10)$$

O bezeichnet die sogenannte *obere asymptotische Schranke der Komplexität*. Bellmann bezeichnet dies als *Fluch der Dimensionen* [Bel57], Luus spricht von der *Plage des wachsenden Netzes* [Luu00]. Eine Visualisierung der resultierenden Matrizen für die Rückwärtsrechnung der DP bei bis zu drei Zustands- und Steuergrößen ist in Abbildung 3.2 zu finden.

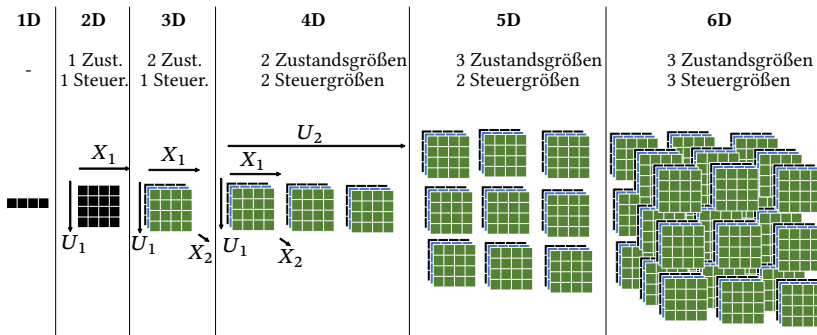


Abbildung 3.2: Visualisierung der Matrizen für die Rückwärtsrechnung der DP bei I Zustandsgrößen und K Steuergrößen.

Ein exemplarisches Anwendungsbeispiel ist in Anhang B aufgezeigt. Für tieferegehende Informationen sei auf [Sun09, Wah15, Ono16, Bau19] verwiesen. Nachdem die DP nun detailliert beschrieben wurde, werden im nachfolgenden Kapitel das PMP und die ECMS eingeführt.

3.3 Pontryagin'sches Minimum-Prinzip (PMP) und Equivalent Consumption Minimization Strategy (ECMS)

Neben der DP existieren weitere Verfahren zum Auffinden der global optimalen Lösung des Steuerungsproblems wie beispielsweise das Pontryagin'sche Minimum-Prinzip (PMP). Hiermit lässt sich der beschriebene *Fluch der Dimensionen* vermeiden. Die Arbeit beschreibt die Anwendung des PMP auf das Energiemanagement für ein HEV. Hierbei wird die sogenannte *Hamiltonfunktion* $H(t)$ aufgestellt, die sich nach Formel 3.11 aus dem Kraftstoffmassenstrom $\dot{m}_{fuel}(t)$, der Änderung des Batterieladezustands $\dot{SOC}(t)$ und dem sogenannten Co-State $\lambda_{PMP}(t)$ zusammensetzt [Ono16]. Der Co-State beschreibt dabei die optimale Gewichtung zwischen der Änderungsrate des Batterieladezustands und des Kraftstoffmassenstroms:

$$H(t) = \dot{m}_{fuel}(t) + \lambda_{PMP}(t) \cdot \dot{SOC}(t) \quad (3.11)$$

$\dot{SOC}(t)$ ergibt sich entsprechend Formel 3.12 aus dem Batteriestrom $I_{bat}(t)$, der Batteriekapazität C und dem Coulombschen Wirkungsgrad der Batterie $\eta_{coul}^{sign(I_{bat}(t))}$ [Ono16]:

$$\dot{SOC}(t) = -\frac{1}{\eta_{coul}^{sign(I_{bat}(t))}} \frac{I_{bat}(t)}{C} \quad (3.12)$$

Der Strom $I_{bat}(t)$ ergibt sich mit dem bekannten Ersatzschaltbild einer Batterie nach Formel 2.6. Die optimale Steuerung ergibt sich entsprechend Formel 3.13. Dabei hängt der Wert der Hamiltonfunktion $H(t)$ vom Batterieladezustand $SOC(t)$, der Batterieleistung $P_{bat}(t)$, dem Co-State $\lambda_{PMP}(t)$ und der benötigten Leistung $P_{req}(t)$ ab. Die Batterieleistung P_{bat} stellt dabei exemplarisch die Steuergröße dar. $P_{req}(t)$ fasst alle mechanischen und elektrischen Lasten zusammen [Ono16]:

$$P_{bat}^* = \min_{P_{bat} \in U_{P_{bat}}} H(SOC(t), P_{bat}(t), \lambda_{PMP}(t), P_{req}(t)) \quad (3.13)$$

Die Bestimmung von $\lambda_{PMP}(t)$ ist dabei herausfordernd. Zunächst muss ein Startwert für λ_{PMP} bestimmt werden, wobei ein in der Praxis verbreiteter Ansatz das sogenannte Schießverfahren (engl.: *Shooting Method*, nachfolgend kurz als SM bezeichnet) darstellt. Dieser Wert wird auch kurz $\lambda_{PMP,0}$ bezeichnet. Das Schießverfahren zielt darauf ab, durch iterative Anpassung eines Anfangswerts $\lambda_{PMP,0}$ den gewünschten Endladezustand SOC_f zu erreichen. Hierzu kann beispielsweise das Bisektionsverfahren zum Einsatz kommen [Gör16, Ono16]. Im Zuge dessen wird entsprechend des PMP für jeden Zeitschritt ein neues Lambda $\lambda_{PMP}(t)$ berechnet. Nach Formel 3.14 gilt für die Änderung des Co-States $\dot{\lambda}_{PMP}$ [Ono16]:

$$\dot{\lambda}_{PMP} = -\lambda_{PMP} \frac{\partial \dot{SOC}}{\partial SOC}(P_{bat}, SOC) \quad (3.14)$$

Der Quotient $\frac{\partial \dot{SOC}}{\partial SOC}$ beschreibt die Ableitung der Ladezustandsänderung \dot{SOC} nach dem Batterieladezustand SOC und kann aus den Batterieeigenschaften bestimmt werden. Zur Veranschaulichung von $\frac{\partial \dot{SOC}}{\partial SOC}$ sei auf Abbildung 4.1 verwiesen. Für den Fall einer vernachlässigbaren Abhängigkeit der Spannung und des Widerstands vom SOC kann nach Formel 3.15 geschrieben werden:

$$\frac{\partial \dot{SOC}}{\partial SOC} = 0 \quad (3.15)$$

Hierdurch ergibt sich nach Formel 3.14 für das Auffinden der optimalen Trajektorie ein konstantes Lambda. In diesem Fall gilt $\lambda_{PMP}(t) = \lambda_{PMP,0}$.

Mittels λ_{PMP} erfolgt in jedem Zeitschritt eine Minimierung entsprechend Formel 3.13. Zum Ende des Fahrzyklus wird der finale Zustand betrachtet und hinsichtlich der globalen Randbedingungen überprüft (vgl. Formel 3.3 bei DP). Ist der finale Ladezustand zu niedrig, muss $\lambda_{PMP,0}$ erhöht werden. Ist der finale Ladezustand zu hoch, muss $\lambda_{PMP,0}$ verringert werden. λ_{PMP} lässt sich somit als Wert der elektrischen Energie interpretieren. Der Fahrzyklus wird mehrmals durchlaufen, bis das optimale $\lambda_{PMP,0}^*$ gefunden wurde, welches den gewünschten Endzustand erreicht. Das Prozedere ist in Abbildung 3.3 im Vergleich zur DP skizziert. SOC_f stellt dabei den finalen Ladezustand der

Batterie dar. Obwohl die Minimierung der Hamiltonfunktion nur lokal erfolgt, kann mit dem PMP eine global optimale Lösung gefunden werden (vgl. Kapitel 3.1).




Abbildung 3.3: Grundlegendes Prinzip der DP (links) im Vergleich zur Offline-ECMS (rechts) unter Verwendung des Schießverfahrens (engl.: *Shooting Method*). Aus Deufel et al. [2].

Fährt beispielsweise ein Fahrzeug erst längere Zeit bergauf, dann längere Zeit bergab, führt dies mit einem durchschnittlichen $\lambda_{PMP,0}$ zu einem deutlich erhöhten Batterieendladezustand SOC_f , da während der Bergabfahrt viel Energie rekuperiert wird. Ein ladungserhaltender Betrieb ist somit nicht gegeben. Entsprechend Abbildung 3.3 wird der Co-State $\lambda_{PMP,0}$ daher im nächsten Durchlauf verringert, wodurch nach Formel 3.11 der Wert der elektrischen Energie sinkt und somit mehr elektrisch gefahren wird. Damit kann das PMP beim Bergauffahren die Batterie weitgehend leer fahren, um sie beim Bergabfahren wieder kostenlos aufzuladen. Durch ein mögliches Erreichen des maximal zulässigen Batterieladezustands könnten jedoch die Rekuperationspotentiale nicht vollständig genutzt werden. Für das Auftreten solcher zeitvarianter Effekte durch Erreichen der Komponentengrenzen sei auf Kapitel 4.3.2 verwiesen.

Entsprechend den Ausführungen von [Kir70, Gör16, Ono16] müssen beim PMP zur Bestimmung der optimalen Lösung notwendige Bedingungen (Formel 3.13, Formel 3.14, sowie der vorgegebene Start- und Endladezustand) erfüllt sein. Unter bestimmten Umständen sind diese Bedingungen nicht nur notwendig, sondern auch hinreichend für eine optimale Lösung. Hierfür

muss entsprechend den mathematischen Nachweisen von [Kim11, Kim12] für eine global optimale Lösung der Kraftstoffmassenstrom \dot{m}_{fuel} eine konvexe Funktion von P_{bat} sein, und die Ableitung \dot{SOC} des SOC eine konkave Funktion von P_{bat} und dem SOC. Diese Konvexität und Konkavität stellen die grundlegenden Eigenschaften eines Steuerungsproblems für HEVs dar. Ein einfaches Praxisbeispiel sowie eine allgemeine Formulierung aller notwendigen Bedingungen des PMP ist in Anhang C zu finden.

Neben dem PMP wurde von Paganelli im Jahre 2001 die ECMS für eine optimale EMS im Onlinebetrieb entwickelt [Pag02]. Hierbei wird eine sogenannte Äquivalenzleistung $P_{eqv}(t)$ bestimmt, die für jeden Zeitschritt unter Verwendung eines sogenannten Äquivalenzfaktors s zu minimieren ist (Formel 3.16):

$$P_{eqv}(t) = P_{fuel}(t) + s(t) \cdot P_{bat}(t) \quad (3.16)$$

Hierbei wird anstatt des Kraftstoffmassenstroms $\dot{m}_{fuel}(t)$ die Leistung aus dem Kraftstoffmassenstrom $P_{fuel}(t)$ berücksichtigt. Ebenso wird anstatt der Änderung des Batterieladezustands $\dot{SOC}(t)$ die Batterieleistung $P_{bat}(t)$ verwendet. Dennoch ist die Ähnlichkeit zum PMP (vgl. Formel 3.11) offensichtlich. Der Co-State λ_{PMP} des PMP lässt sich somit als Äquivalenzfaktor s der ECMS interpretieren [Sch22]. Im Rahmen der Arbeit wird im weiteren Verlauf vom Äquivalenzfaktor λ gesprochen. Ein entsprechender Nachweis der Äquivalenz der beiden Verfahren erfolgt in [Ono16]. Auch [Hel15] bestätigt die Äquivalenz von PMP und ECMS. Es lässt sich entsprechend schlussfolgern, dass Formel 3.11 (PMP) und 3.16 (ECMS) sowohl für Offline- als auch für Onlinebetrachtungen gleichwertig verwendet werden können. Im Onlinebetrieb muss der Äquivalenzfaktor λ möglichst optimal geschätzt bzw. durch geeignete Maßnahmen online adaptiert werden, da eine iterative Bestimmung nicht möglich ist (Ausnahme: Innerhalb des Prädiktionshorizonts einer MPC). Offline kann λ mittels des erwähnten Schießverfahrens (SM) bestimmt werden.

Auch in der Literatur werden die Begriffe PMP und der ECMS zur Beschreibung ein und der selben Formel verwendet. Es zeichnet sich jedoch ab, dass bei einer iterativen Anwendung im Bereich der Offline-Optimierung unter

Verwendung der SM primär vom PMP und in der Online-Optimierung überwiegend von ECMS gesprochen wird. Allerdings hat sich auch der Begriff der sogenannten *Offline-ECMS* etabliert [Adh10, Cha11, Thi13, Sci14, Wei18, Acc20, Don20, Par22, Sil22], insbesondere wenn zur Einhaltung weiterer Randbedingungen (z. B. Einschränkung des Start/Stop-Verhaltens der VKM) weitere Zustandsgrößen in das Optimierungsproblem einfließen. Damit kann das eigentliche Optimierungsproblem zwar auf weitere Zielgrößen als die reine Kraftstoffminimierung erweitert werden, eine Optimalität entsprechend des PMP ist jedoch nicht mehr zwingend gegeben. So schreibt [Gör16]: *”[Das PMP] ist jedoch [...] auf [...] Problemstellungen mit nur einer kontinuierlichen Steuergröße wie die der Drehmomentaufteilung bei Hybridfahrzeugen beschränkt. [...] [Eine] Entscheidung über den Wechsel zwischen der elektrischen Fahrt und dem Hybridmodus unter Einbeziehung des Energiebedarfs des [VKM-Starts kann] nicht rein aus lokaler Sicht getroffen werden [...]. Ohne das Wissen über das zukünftige Fahrprofil kann [...] nicht entschieden werden, ob sich ein [VKM-Start] aus globaler Sicht lohnt”*.

Im Rahmen der Arbeit wird der von [För24] implementierte Algorithmus einer ECMS verwendet. Dies stellt eine abgewandelte Variante der Formeln 3.11 und Formel 3.16 dar (Formel 3.17). Dabei wird der Kraftstoffmassenstrom \dot{m}_{fuel} und die Batterieleistung P_{bat} herangezogen, wobei letztere durch den unteren Heizwert H_u dividiert wird. Es ergibt sich ein äquivalenter Kraftstoffmassenstrom \dot{m}_{eqv} , siehe auch [Gör16].

$$\dot{m}_{eqv}(t) = \dot{m}_{fuel}(t) + \lambda(t) \cdot \frac{P_{bat}(t)}{H_u} \quad (3.17)$$

Die Implementierung umfasst zudem auch eine Erweiterung von Formel 3.17 zur Einschränkung des Start/Stop-Verhaltens der VKM entsprechend Formel 3.18:

$$\dot{m}_{eqv,ICE,stsp}(t) = kp_{stsp} \cdot \dot{m}_{eqv}(t) \quad (3.18)$$

Über den frei wählbaren Parameter kp_{stsp} werden die Zustandsübergänge im Falle eines Start- oder Stoppvorgangs der VKM bestraft und der äquivalente Kraftstoffmassenstrom $\dot{m}_{eqv}(t)$ für die Steuergrößen entsprechend erhöht.

Damit ergibt sich der äquivalente Kraftstoffmassenstrom inkl. Starts/Stopps der VKM $\dot{m}_{equ,ICE,stop}$. Ebenso kann eine Mindestlaufzeit für die VKM festgelegt werden ($\tau_{ICE,min}$).

Wenn nicht anders beschrieben, wird im Folgenden mit **Offline-ECMS** die Anwendung des PMP mit iterativ bestimmtem, konstanten λ_0 bezeichnet. Mit **Online-ECMS** wird hingegen eine EMS ohne Iterationen für die potentielle Onlineanwendung bezeichnet. Der Begriff des **PMP** findet keine weitere Anwendung. Für den Fall einer Optimierung über einen begrenzten Zeithorizont im Rahmen einer konventionellen Modellprädiktiven Regelung (MPC) lässt sich die Offline-ECMS aber auch auf einen Onlineeinsatz übertragen [Xie19]. Dabei wird die Offline-ECMS zur Bestimmung einer optimalen EMS iterativ innerhalb des Prädiktionshorizonts angewandt. Siehe hierzu auch das Folgekapitel 3.4.

Nachdem nun ein Überblick zu Energiemanagementstrategien im Allgemeinen gegeben wurde, und auch die DP, das PMP und die ECMS, welche den Fokus dieser Arbeit darstellen, detailliert eingeführt wurden, wird im nachfolgenden Kapitel der Einsatz prädiktiver EMS gesondert diskutiert.

3.4 Prädiktives Energiemanagement

Wie bereits in Kapitel 1.2 und Kapitel 3 beschrieben, werden im Rahmen der Arbeit die Prädiktion und der Optimierer getrennt voneinander betrachtet. Daher wird im Rahmen dieses Kapitels zunächst der Grundgedanke einer Modellprädiktiven Regelung im Allgemeinen beschrieben. Anschließend wird aufgezeigt, mit welchen Verfahren die hierfür notwendigen Prädiktionen erfolgen können. In einem weiteren Kapitel wird beschrieben, wie entsprechende Prädiktionen im Rahmen prädiktiver EMS verwendet werden können.

3.4.1 Grundlagen der Modellprädiktiven Regelung (MPC)

Wie bereits in Kapitel 3.1 beschrieben, sind prädiktive EMS durch die Berücksichtigung zusätzlicher Informationen besonders vielversprechend und sollen daher tiefergehenden Untersuchungen unterzogen werden. Bei einer Modellprädiktiven Regelung (MPC) muss das Systemverhalten für einen bestimmten Prädiktionshorizont vorhergesagt werden, wobei relevante Größen aus Vergangenheit und Zukunft miteinbezogen werden. Der Prädiktionshorizont muss passend gewählt werden. Durch einen zu kurzen Prädiktionshorizont werden vom Optimierer wichtige Informationen nicht berücksichtigt, wie beispielsweise eine mit einer anstehenden Bergabfahrt in Zusammenhang stehende Rekuperationsphase. Ein großer Prädiktionshorizont geht mit einer steigenden Unschärfe der Prädiktionen und einem bei einer unveränderten, zeitlichen Auflösung größeren Rechenaufwand einher. Wie in Abbildung 3.4 aufgezeigt, wird zunächst basierend auf der prädizierten Fahrzeuggeschwindigkeit v , der prädizierten Fahrzeugbeschleunigung a und der prädizierten Fahrbahnsteigung α mittels eines Längsdynamikmodells die zukünftige Drehmomentanforderung T_{req} berechnet. Hierauf wird durch einen geeigneten Optimierer die entsprechende Steuergröße bestimmt (vgl. Deufel et al. [1]). Dabei gibt τ_{pred} die Länge des Zeitfensters für die Prädiktion an und $\tau_{control}$ die Länge des Zeitfensters für die Steuerung.

Die Lösung des Optimierungsproblems innerhalb des Prädiktionshorizonts kann beispielsweise mittels der DP [Bac06, Wah15, Bau19] aber auch anderen Verfahren erfolgen (vgl. Abschnitt 3.1). Da das prädizierte Systemverhalten die Realität nur annähernd abbildet, wird im Normalfall nur der erste Wert der über den Prädiktionshorizont berechneten, optimalen Steuerungen tatsächlich ausgegeben [Bac06]. Üblicherweise erfolgen für den nächsten Zeitschritt stets eine erneute Prädiktion und Optimierung, basierend auf dem tatsächlich eingetretenen Zustand. Man spricht von einem *gleitenden Horizont* [Wah15]. Alternativ zum beschriebenen Ablauf einer klassischen Modellprädiktiven Regelung kann auch eine Online-ECMS durch die prädizierten Größen angereichert werden, ohne dass zwingend eine Optimierung über den gesamten

Prädiktionshorizont erfolgt. Die Konzeptionierung einer entsprechenden prädiktiven Online-ECMS, welche die aus den Prädiktionen resultierenden Rekuperationspotentiale berücksichtigt, ist in Kapitel 6.3 beschrieben.

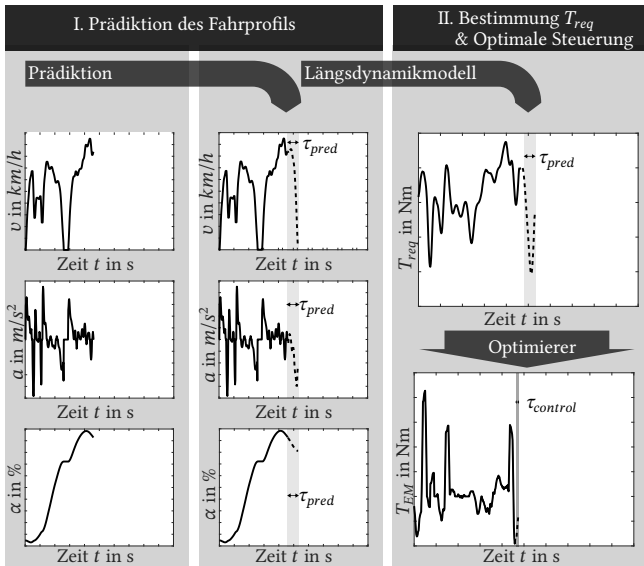


Abbildung 3.4: Grundprinzip einer Modellprädiktiven Regelung (MPC) mit dem Prädiktionshorizont τ_{pred} und dem Steuerungshorizont $\tau_{control}$ aus Deufel et al. [1]. Vereinfachte Darstellung basierend auf [Fin02, Dit06].

Die Prädiktion von Fahrzeuggeschwindigkeit, Fahrzeugbeschleunigung und Fahrbahnsteigung ist keinesfalls trivial. [Još18] unterscheidet fünf Varianten der Prädiktion:

- Die *Frozen Time* Prädiktion, bei welcher der Drehmomentbedarf über den Vorhersagehorizont konstant gehalten wird.
- Die *Precient* Prädiktion, bei welcher der zukünftige Drehmomentbedarf a priori perfekt bekannt ist.
- Die *exponentially varying* Prädiktion, bei welcher der Drehmomentbedarf über den Vorhersagehorizont exponentiell abnimmt.

- Die Prädiktion mit sogenannten *Markov-Ketten*.
- Die *Artificial MPC* basierend auf Methoden der Künstlichen Intelligenz (AI).

Eine ähnliche Einteilung findet sich auch in [Hua17, Zho21]. Wie bereits in [S3] bzw. Deufel et al. [3] beschrieben, existieren aber auch alternative Unterteilungen: In [Lef14, Yuf19] wird beispielsweise zwischen parametrischen und nichtparametrischen Methoden differenziert.

- Parametrische Methoden (PM) basieren auf analytischen Funktionen. Hierzu gehört beispielsweise die von [Rez15] beschriebene Fahrzeuggeschwindigkeitsvorhersage anhand von GNSS-Daten, wenn die zu fahrende Strecke im Voraus bekannt ist. Dabei wird die Strecke in Segmente gleicher Maximalgeschwindigkeit unterteilt, deren Übergänge mit Fahrzeugbeschleunigungs- und Bremsphasen beschrieben werden. Solche Vorhersagen können für die gesamte Strecke gemacht werden. Dynamische Einflüsse, die kurzfristig aus der jeweiligen Verkehrssituation resultieren, können jedoch nur schwer berücksichtigt werden (vgl. Deufel et al. [3]). Eine beispielhafte Implementierung im Rahmen der Forschungsarbeiten wurde durch [S3] realisiert.
- Nichtparametrische Methoden (NPM) erfordern keine Vorkenntnisse über die genaue Dynamik des Systems. Daher eignen sie sich gut für die Modellierung von Systemen, deren physikalische Grundlagen nicht einfach zu beschreiben oder sogar unbekannt sind. Außerdem kann eine robuste Anwendung gewährleistet werden, da die Route nicht zwingend im Voraus bekannt sein muss und Prädiktionen auch ohne zusätzliche Informationen über das zukünftige Fahrgeschwindigkeitsprofil möglich sind. Beispiele hierfür sind die bereits in der Unterteilung nach [Još18] genannten Methoden aus dem Bereich der Stochastik wie Markov-Ketten (MC) und Methoden aus dem Bereich des Maschinellen Lernens wie Künstliche Neuronale Netze (ANN), vgl. Deufel et al. [3].

Eine weitere Möglichkeit zur Vorhersage des Fahrgeschwindigkeitsprofils ist die Berücksichtigung einer historischen Durchschnittsgeschwindigkeit an einem bestimmten Wochentag zu einer bestimmten Uhrzeit auf einem bestimmten Streckenabschnitt. Eine andere Möglichkeit ist aber auch, dass der Geschwindigkeitsverlauf durch einen Optimierer optimal für eine vorgegebene Route gewählt wird, beispielsweise durch Verwendung eines entsprechenden Geschwindigkeitregelsystems. Diese zusätzliche Möglichkeit der Geschwindigkeitswahl durch einen Optimierer, wird im Rahmen der Arbeit grundsätzlich nicht näher betrachtet. Wie bereits erwähnt, beschränkt sich die Arbeit auf reale Fahrgeschwindigkeitsprofile ohne den Freiheitsgrad einer frei wählbaren Geschwindigkeit. Nachdem nun der Grundgedanke einer Modellprädiktiven Regelung im Allgemeinen beschrieben und eine mögliche Einteilungen der Verfahren zur Prädiktion der zukünftigen Drehmomentanforderung in der Literatur vorgestellt wurde, wird im Folgekapitel zunächst auf die Komplexität der Prädiktion realer Fahrgeschwindigkeitsprofile eingegangen. Anschließend werden hierauf basierend geeignete Verfahren zur Prädiktion identifiziert und diese vorgestellt.

3.4.2 Prädiktion realer Fahrgeschwindigkeitsprofile

Wie von [S3] bzw. Deufel et al. [3] beschrieben, sind die relevanten Größen Fahrzeuggeschwindigkeit, Fahrzeugbeschleunigung und Fahrbahnsteigung zur Vorhersage der mechanischen Lasten (Abbildung 2.2) im Allgemeinen von Fahrzeug, Fahrer und Umwelt abhängig [Lef14, Yan20].

Grundsätzlich existiert ein breites Spektrum an **Fahrzeugen**. Wie in [Al 15] gezeigt wurde, sind je nach Fahrzeugtyp unter gleichen Bedingungen große Unterschiede in den Durchschnittsgeschwindigkeiten festzustellen. Darüber hinaus sind auch die erzielbaren Höchstgeschwindigkeiten im Laufe der Automobilentwicklung infolge einer höheren Leistungsfähigkeit der Antriebe stetig gestiegen. Damit ist ein deutlicher Abwärtstrend der Fahrzeuggeschwindigkeit mit zunehmendem Fahrzeugalter zu beobachten. Ebenso entscheidend für die Fahrzeuggeschwindigkeit ist der **Fahrer** selbst [Yuf19]. Laut [Qui99]

sind hier demografische Merkmale wie Alter und Geschlecht sowie der Charakter und die aktuelle Stimmung entscheidend. In [Sag05] wird auch ein Einfluss der subjektiven Wahrnehmung des Fahrers in Bezug auf die Qualität der Straße erwähnt. Darüber hinaus gibt die **Infrastruktur** durch gesetzliche Vorgaben oder Fahrempfehlungen Randbedingungen vor, die das Fahrzeuggeschwindigkeitsprofil einer Strecke maßgeblich beeinflussen [Lar20]. Nach [Hel20] sind hier Ampeln und Kreuzungen entscheidend. Ebenso spielen Geschwindigkeitsbegrenzungen eine wichtige Rolle. Durch Wetter, Tageszeit oder Lichtverhältnisse hat auch die **Umwelt** einen großen Einfluss. [Qui99] weisen auf einen Unterschied zwischen Tag- und Nachtfahrten hin. Außerdem relevant ist die **Straße** selbst. Nicht nur die Fahrbahnoberfläche, sondern auch die Krümmung hat einen relevanten Einfluss auf das Fahrzeuggeschwindigkeitsprofil [Rez15]. Insbesondere in Kurven ist der begrenzende Faktor in der Regel nicht die zulässige Höchstgeschwindigkeit, sondern die vom Fahrer akzeptierte maximale Querbeschleunigung. [Bac06, Hel20] messen der Berücksichtigung von Kurven daher eine hohe Relevanz bei, vor allem im Stadtverkehr. Auch die Fahrbahnsteigung kann einen nicht zu vernachlässigenden Einfluss haben, vor allem bei Bergauffahrten. Der **Verkehr** ist generell dynamisch und schwer prognostizierbar, da er stark von anderen Verkehrsteilnehmern beeinflusst wird. Ein schematischer Überblick der Einflüsse ist in Abbildung 3.5 dargestellt (vgl. Deufel et al. [3]).

Anhand von Kartendaten lassen sich statische Verkehrsereignisse wie die Position von Ampeln oder Stoppschildern erkennen. Darüber hinaus können sogenannte Live Maps zeitabhängige Informationen wie Staus und Verkehrsdichte liefern. Ebenso kann das Fahrzeug selbst über bordeigene Sensorsysteme wie Radarsysteme oder Kameras verfügen, die Informationen über den beobachteten Verkehr liefern, zum Beispiel den Abstand zum vorausfahrenden Fahrzeug [Bac06], vgl. Deufel et al. [3].

Zusammenfassend lässt sich sagen, dass datengetriebene Methoden aus dem Bereich der NPM aufgrund der beschriebenen Komplexität hervorragend für die Modellierung des Fahrverhaltens bzw. die damit verbundene Prognose des Fahrgeschwindigkeitsprofils geeignet sind.

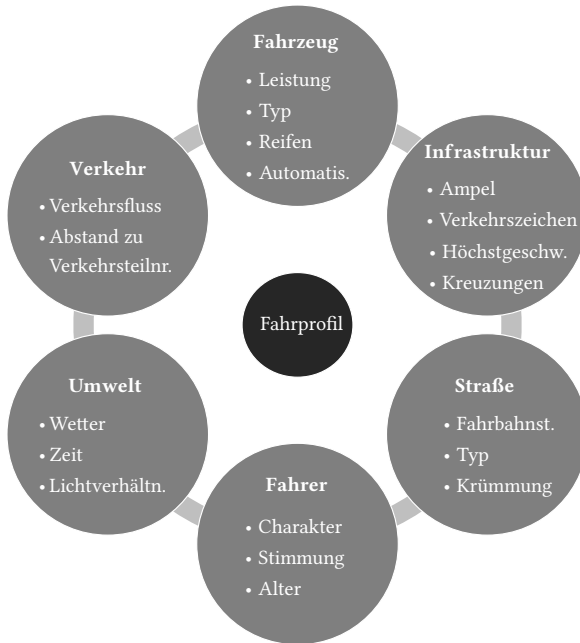


Abbildung 3.5: Überblick über die Einflüsse auf das Fahrgeschwindigkeitsprofil, angelehnt an Deufel et al. [3].

Diese Arbeit beschränkt sich dabei auf Vorhersagen mit kurzem Prädiktionshorizont, da zur optimalen Nutzung des elektromotorisch und verbrennungsmotorisch bereitgestellten Drehmomentes die erwarteten Lastpunkte in der nahen Zukunft relevant sind (Näheres hierzu siehe Kapitel 6.3). Im Rahmen der Arbeit werden Prädiktionen von Markov-Ketten (engl. *Markov Chains*, kurz MC) mit Prädiktionen von Vorwärtsgerichteten Neuronalen Netzen (engl. *Feedforward Neural Networks*, kurz FFNN) verglichen. Ebenso werden Rekurrente Neuronale Netze (engl. *Recurrent Neural Networks*, kurz RNN) untersucht, da sich diese besonders gut für Zeitreihenvorhersagen eignen [Cha21]. Die Grundlagen zu den näher untersuchten Verfahren werden nachfolgend vorgestellt. Die Erklärungen inklusive der referenzierten Anhänge sind aus Deufel et al. [1] und [3] entnommen.

Markov-Ketten

Eine Markov-Kette verwendet Wissen aus der Vergangenheit eines begrenzten, zurückliegenden Zeitraums, um das Eintreten einzelner Zustände zu schätzen. Bei diskreten Markov-Prozessen werden die Zustände eines Systems hierfür zunächst diskretisiert. Dies ermöglicht die Berechnung der Übergangswahrscheinlichkeit, welcher Folgezustand bei einem bestimmten Istzustand eintritt. Diese Übergangswahrscheinlichkeiten wiederum werden in einer Übergangswahrscheinlichkeitsmatrix (engl. *Transition Probability Matrix*, kurz TPM) gespeichert, siehe Abbildung 3.6. Dabei ist die Übergangswahrscheinlichkeit P_{TPM} zwischen den Zuständen S_i und S_j dargestellt. Wenn sich diese Wahrscheinlichkeitsverteilung auf den aktuellen Zustand beschränkt, ohne vergangene Werte zu berücksichtigen, kann dies als MC erster Ordnung bezeichnet werden (vgl. Deufel et al. [1]).




Abbildung 3.6: Visualisierung der Übergangswahrscheinlichkeitsmatrix (engl. *Transition Probability Matrix*, kurz TPM) aus Deufel et al. [1].

Entsprechend [Rab89] wird der Zustand zum Zeitpunkt t als q_t bezeichnet. Damit gilt für die Übergangswahrscheinlichkeit P_{TPM} nach Formel 3.19, vgl. Deufel et al. [1]:

$$P_{TPM} [q_t = S_j | q_{t-1} = S_i] \quad (3.19)$$

Da nur zeitinvariante Prozesse betrachtet werden, lässt sich entsprechend Formel 3.20 für die Übergangswahrscheinlichkeit a_{ij} vom Zustand i zum Zustand j schreiben [Rab89], vgl. Deufel et al. [1]:

$$a_{ij} = P_{TPM} [q_t = S_j | q_{t-1} = S_i] \quad (3.20)$$

Darüber hinaus gelten nach Formel 3.21 und 3.22 folgende Randbedingungen [Rab89], vgl. Deufel et al. [1]:

$$a_{ij} \geq 0 \quad (3.21)$$

$$\sum_{j=1}^N a_{ij} = 1 \quad (3.22)$$

Vorwärtsgerichtete Neuronale Netze (FFNN)

Ein Vorwärtsgerichtetes Neuronales Netz (FFNN) besteht in der Regel aus einer Eingangsschicht, einer Ausgabeschicht und mehreren versteckten Schichten. Die grundlegenden Berechnungen werden am Beispiel eines ANN mit einem einzigen Ausgangsneuron - einem sogenannten Perzeptron - dargestellt (Abbildung 3.7). Dabei sind die Eingänge x_j , die Gewichtung der einzelnen Verbindungen w_i sowie der Ausgangswert \hat{y} kenntlich gemacht (vgl. Deufel et al. [1]).




Abbildung 3.7: Grundlegende Architektur eines Perzeptrons aus Deufel et al. [1] in Anlehnung an [Agg18].

Der Ausgangswert \hat{y} ergibt sich aus der Berücksichtigung der Eingangswerte $X = [x_1, \dots, x_d]$, die den d Merkmalen entsprechen, dem Bias b , den Gewichtungen der Verbindungen zwischen der Eingangsschicht und dem Ausgangsneuron $W = [w_1, \dots, w_d]$ sowie der Aktivierungsfunktion θ gemäß Formel 3.23 [Agg18], vgl. Deufel et al. [1]:

$$\hat{y} = \theta \{W \cdot X + b\} = \theta \left\{ \sum_{j=1}^d w_j \cdot x_j + b \right\} \quad (3.23)$$

Dabei wird die Aktivierungsfunktion auf die gewichtete Summe der Eingabewerte angewendet und bestimmt so letztlich den Ausgabewert des Neurons. Eine typische Aktivierungsfunktion ist z. B. die Rectified Linear Unit (ReLU). Je nach Anwendung können aber auch andere Funktionen verwendet werden [Agg18]. Dieses Grundprinzip lässt sich auch auf komplexere ANN übertragen. Hier ergeben die Ausgangswerte einer Schicht die Eingangswerte für die Neuronen der nächsten Schicht. Für einen umfassenden Überblick über FFNN einschließlich der verschiedenen Kalibrierungsmöglichkeiten wird auf [Agg18] verwiesen (vgl. Deufel et al. [1]).

Rekurrente Neuronale Netze (RNN)

Die grundlegende Architektur eines RNN ist in Abbildung 3.8 dargestellt [LeC15], vgl. Deufel et al. [3].




Abbildung 3.8: Rekurrentes Neuronales Netz (RNN) aus Deufel et al. [1] in Anlehnung an [Agg18].

Im einfachsten RNN, einem sogenannten Vanilla RNN, wird der verborgene Zustand h_t mithilfe der Parametergewichte W_{hh} (Gewichtung verborgener Zustand zu verborgener Zustand), W_{xh} (Gewichtung Eingang zu verborgener Zustand), dem Eingang x_t und dem verborgenen Zustand im letzten Zeitschritt h_{t-1} berechnet. Ein \tanh wird verwendet, um den verborgenen Zustand im aktuellen Zeitschritt h_t zwischen -1 und 1 zu halten. Die Ausgabe y_t wird schließlich durch die Multiplikation des verborgenen Zustands im aktuellen Zeitschritt h_t mit einem weiteren Parametergewicht W_{hy} (Gewichtung verborgener Zustand zu Ausgang) berechnet [Li17, Agg18]. Weitere Informationen zu RNNs sind in [Wer88, Elm90, Goo16] zu finden. Entsprechend Formel 3.24 und 3.25 gilt somit (vgl. Deufel et al. [3]):

$$h_t = \tanh(W_{hh} \cdot h_{t-1} + W_{xh} \cdot x_t) \quad (3.24)$$

$$y_t = W_{hy} \cdot h_t \quad (3.25)$$

Die Parameterbestimmung des RNN erfolgt analog zum FFNN mittels der sogenannten Rückpropagierung (engl. *Backpropagation*). Dabei werden mittels des Gradientenverfahrens die Gewichte rückwärtsgerichtet, von der Ausgabeschicht über die versteckten Schichten bis zur Eingabeschicht, angepasst. Bei dieser rückwärtsgerichteten Weitergabe des Fehlers besteht das Risiko, dass Gradienten verschwinden, wodurch die Zellen nicht weiter trainiert werden. In der Literatur wird auch vom *Problem der verschwindenden und explodierenden Gradienten* (engl. *Vanishing and Exploding Gradient Problem*) gesprochen [Agg18, Hol23]. Dadurch haben einfache RNNs Schwierigkeiten bei der Berücksichtigung langfristiger Abhängigkeiten. Aus diesem Grund wurden von [Hoc97] RNNs mit langem Kurzzeitgedächtnis (engl. *Long Short-Term Memory*, kurz *LSTM*) eingeführt. Im Gegensatz zu einfachen RNNs enthalten LSTMs neben dem verborgenen Zustand h_t einen Zellzustand C_t . Der Zellzustand kann als Langzeitgedächtnis des Modells betrachtet werden. Gleichzeitig enthält ein LSTM auch zwei Arten von Aktivierungsfunktionen: *tanh* und *sigmoid*. *Tanh* begrenzt, ähnlich wie beim *Vanilla RNN*, den Datenfluss auf Werte zwischen -1 und 1. *Sigmoid* legt fest, ob bestimmte

Informationen aktualisiert oder vergessen werden (Werte zwischen 0 und 1). Ein Überblick über eine LSTM-Zelle ist in Abbildung 3.9 dargestellt. Die verschiedenen Teile eines grundlegenden LSTM werden im Folgenden kurz vorgestellt [Gra13, Gra14, Agg18, Jia18], vgl. Deufel et al. [3].

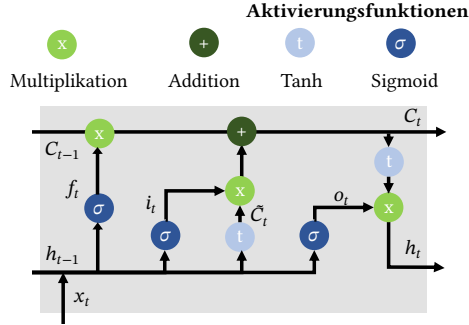


Abbildung 3.9: Architektur einer LSTM-Zelle eines Rekurrenten Neuronales Netzes (RNN) aus Deufel et al. [3]. Basierend auf [Che18].

Basierend auf dem vorherigen verborgenen Zustand h_{t-1} und dem aktuellen Zustand x_t wird der Ausgang f_t des *Forget Gates* mittels einer Sigmoidfunktion berechnet. Damit wird festgelegt, ob Informationen aus dem vorherigen Zellzustand C_{t-1} behalten oder vergessen werden. Anschließend werden neue Informationen im Zellzustand gespeichert: Dazu wird ein *Input Gate* verwendet. Hierbei entscheidet eine Sigmoidfunktion, welche Werte zu aktualisieren sind. Gleichzeitig werden mittels einer *tanh*-Funktion neue Kandidaten für den Zellzustand \tilde{C}_t bestimmt. Der neue Zellzustand C_t ergibt sich somit als Ausgang f_t des *Forget Gates* f_t , dem alten Zellzustand C_{t-1} , dem Ausgang des *Input Gate* i_t und den neuen Kandidatenwerten \tilde{C}_t (Formel 3.26), vgl. Deufel et al. [3]:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (3.26)$$

Der neue verborgene Zustand h_t wird schließlich berechnet, indem sowohl der zuvor ausgeblendete Zustand h_{t-1} als auch der aktuelle Zustand x_t durch eine Sigmoidfunktion geleitet werden (*Output Gate* o_t). Hierdurch wird festgelegt, welche Informationen weitergegeben werden. Außerdem

wird auf den neuen Zellzustand C_t eine \tanh -Funktion angewendet. Der neue verborgene Zustand h_t wird schließlich durch Multiplikation wie folgt berechnet (Formel 3.27), vgl. Deufel et al. [3]:

$$h_t = o_t \cdot \tanh(C_t) \quad (3.27)$$

Es ist zu beachten, dass nicht alle LSTMs gleich sind. Eine populäre Version eines LSTM mit Gucklöchern (engl. *peephole*-Verbindungen) wurde zum Beispiel von [Ger00] vorgestellt. Außerdem gibt es LSTM-Modifikationen ohne *Output Gate* o_t , wie beispielsweise Gated Recurrent Units (GRU) [Now17] (vgl. Deufel et al. [3]). GRUs lassen sich aufgrund der geringeren Parameteranzahl leichter trainieren, bei ausreichender Datenmenge ist jedoch ein LSTM zu bevorzugen [Chu14, Joz15, Gre17, Agg18]. Die Entwicklung und Anwendung der beschriebenen Methoden zur Prädiktion des zukünftigen Fahrgeschwindigkeitsprofils erfolgt in Kapitel 6.

Nachdem nun die Herausforderung der Prädiktion realer Fahrgeschwindigkeitsprofile aufgezeigt und verschiedene datengetriebene Methoden zur Modellierung des Fahrverhaltens vorgestellt wurden, wird im Folgekapitel auf prädiktive EMS selbst eingegangen.

3.4.3 Prädiktive EMS

Wie bereits in Kapitel 3.1 beschrieben, bestehen grundsätzlich verschiedene Ansätze zur Realisierung einer prädiktiven EMS. Hierzu wurden einige Voruntersuchungen durchgeführt. Für eine bestmögliche Vergleichbarkeit der prädiktiven Ansätze werden dabei stets *Precient* Prädiktionen verwendet (vgl. Unterteilung nach [Još18] in Abschnitt 3.4.1), bei denen der zukünftige Drehmomentbedarf a priori perfekt bekannt ist. [S4] konnte zeigen, dass eine konventionelle MPC selbst bei perfekter Kenntnis des anstehenden Fahrgeschwindigkeitsprofils über einen festgelegten Zeithorizont in einem darüber hinausgehenden Fahrzyklus hohe Abweichungen zum theoretischen Optimum aufweist. [S11] konnte die Abweichungen im Rahmen weiterer Untersuchungen bestätigen. Zudem zeigte sich, dass die Rechenzeiten bei

Anwendung der MPC mit einer DP ohne weitere Maßnahmen sehr hoch ausfallen. Während hohe Rechenzeiten im Rahmen der Offline-Systemauslegung ungünstig, aber hinnehmbar sind, ist eine Onlineanwendung bei entsprechend hohen Rechenzeiten nicht möglich. Wie bereits in Kapitel 3.1 erwähnt, wurden grundsätzliche Untersuchungen zur Beschleunigung des Algorithmus der DP durch [S10] angestellt. Tiefergehende Untersuchungen für optimales EMS im Onlinebetrieb mittels klassischer MPC entfallen jedoch im Rahmen der vorliegenden Arbeit. Entscheidend für den Verzicht auf weitere Untersuchungen ist neben den aufgezeigten Nachteilen in Puncto Kraftstoffeinsparpotential und Rechenzeit vor allem die Notwendigkeit einer zuverlässigen Prädiktion, was im Widerspruch zu einer robusten Anwendbarkeit der Methodik steht. Ohne Prädiktionen ist eine MPC nicht einsetzbar (Ausnahmen: *Frozen Time* Prädiktion und *exponentially varying* Prädiktion, Abschnitt 3.4.1). Alternativ zu einer konventionellen MPC, bei der unter hohem Rechenaufwand über einen gewissen Prädiktionshorizont optimiert wird, kann, wie bereits in Kapitel 3.1 erwähnt, auch eine nichtprädiktive Online-ECMS durch prädiktive Informationen angereichert werden. Dabei können die Prädiktionen für die Verbesserung der bestehenden, nichtprädiktiven Online-ECMS genutzt werden, ohne dass prädiktive Informationen für den Betrieb der Online-ECMS zwingend notwendig sind. In Kapitel 6 wird ein entsprechendes, eigenes Konzept für eine prädiktive Online-ECMS vorgestellt, mit welchem durch die Berücksichtigung von Rekuperationspotentialen im zukünftigen Horizont zusätzliche Einsparpotentiale generiert werden können. Zusätzlich wird noch ein alternatives Konzept vorgestellt, wie für den Spezialfall einer bekannten Route Einsparpotentiale durch die Berücksichtigung der Ampelpositionen aufgezeigt werden können.

Nachdem bereits in Kapitel 3.1 ein Überblick zu Energiemanagementstrategien im Allgemeinen gegeben wurde und ausgewählte Verfahren detailliert eingeführt worden sind (Kapitel 3.2 und Kapitel 3.3), ist nun auch prädiktives EMS erläutert worden. Dabei wurde zunächst der Grundgedanke einer Modellprädiktiven Regelung im Allgemeinen eingeführt. Ebenso wurden entsprechende Einteilungen der Verfahren zur Prädiktion relevanter Größen aus

der Literatur aufgezeigt. Nachdem die Komplexität der Prädiktion realer Fahrgeschwindigkeitsprofile beschrieben wurde, folgte eine Erläuterung, mit welchen Verfahren die Prädiktionen erfolgen können. Darauf folgend wurde beschrieben, wie entsprechende Prädiktionen im Rahmen prädiktiver EMS herangezogen werden können. Basierend auf diesen Erkenntnissen wird nun abschließend der Forschungsbedarf für EMS für 48 V-Systeme durch eine tabellarische Übersicht im nachfolgenden Kapitel aufgezeigt.

3.5 Forschungsbedarf Energiemanagementstrategien (48 V-System)

Wie in Kapitel 3.1 erwähnt, existieren bereits einige Übersichten zu EMS im Allgemeinen. Die abschließende Tabelle 3.1 zur Identifikation des Forschungsbedarfs beschränkt sich deshalb auf Forschungsarbeiten, die eine besonders hohe Relevanz zur vorgestellten Forschungsfrage bzw. den aufgezeigten Forschungsfeldern aufweisen und anhand der Voruntersuchungen als für die Problemstellung geeignete Verfahren identifiziert werden konnten. Die Voruntersuchungen umfassen die in Kapitel 3.1 vorgenommene Einordnung bestehender Ansätze sowie die exemplarischen Umsetzungen im Rahmen der genannten studentischen sowie eigener, in der vorliegenden Dissertationsschrift nicht weiter dokumentierter Arbeiten. In der abschließenden Tabelle wird nun gezeigt, inwiefern ausgewählte Arbeiten den Themengebieten *EMS in der Systemauslegung*, *(Prädiktive) EMS für den Onlineeinsatz* und *Prädiktionen für den Onlineeinsatz* zugeordnet werden können. Dabei werden die verwendeten Prädiktionsverfahren entsprechend der im Rahmen der Arbeit vorgenommenen strikten Trennung zwischen Prädiktion und dem Optimierer (vgl. Kapitel 1.2 und Kapitel 3) separiert von der EMS gelistet. Zusätzlich wird aufgeführt, welche Optimierungsziele untersucht wurden, ob ein 48 V-System betrachtet wurde und ob die jeweilige Arbeit einen Einsatz unter realen Betriebsbedingungen berücksichtigt hat. Aufgrund der hohen Anzahl der publizierten Arbeiten erhebt die Tabelle kein Anspruch auf Vollständigkeit.

Tabelle 3.1: Vergleich von Arbeiten über EMS von elektrifizierten Fahrzeugantrieben in der Literatur. Kategorisiert nach 1) EMS in der Systemauslegung 2) (Prädiktive) EMS für den Onlineeinsatz 3) Prädiktionen für den Onlineeinsatz 4) Berücksichtigte Optimierungsziele der EMS 5) Verwendung eines 48 V-Systems 6) Untersuchung realer Betriebsbedingungen.

	Ausl.	Online				Prädiktion			Ziele			48 V	Real
	DP	Offline-ECMS / PMP	Online-ECMS	Online-ECMS Präd.	MPC	MC	FFNN	RNN	Kraftstoff / CO ₂ -Emiss.	VKM-Start/Stop	Weitere Zielgrößen		
Sun08	✓								✓				
Sun09	✓								✓				
Sun10	✓								✓				
Elb13	✓								✓				
Kim11	✓	✓							✓				
Kim12	✓	✓							✓				
Ser09b		✓							✓				
Zhe14		✓							✓				
May19		✓							✓				
Ono11		✓	✓						✓				
Ono10	✓	✓	✓						✓				
Mus05	✓	✓	✓						✓				
Cha10		✓	✓						✓				
Kes08	✓	✓	✓						✓				
Liu14			✓						✓				
Oud18		✓	✓						✓				
Siv12		✓	✓						✓				
Zha18		✓	✓						✓				
Fu17			✓						✓				
Ena17			✓						✓				
Kur15	✓	✓	✓	✓					✓				
Gao17		✓	✓	✓					✓				
Han17			✓	✓					✓				
Zha17		✓	✓	✓					✓				
Che20		✓	✓	✓					✓				
Kaz17			✓	✓					✓				
Bou17			✓	✓					✓				

	Ausl.	Online				Prädiktion			Ziele			48 V	Real
	DP	Offline-ECMS / PMP	Online-ECMS	Online-ECMS Präd.	MPC	MC	FFNN	RNN	Kraftstoff / CO ₂ -Emiss.	VKM-Start/Stopp	Weitere Zielgrößen		
Wah15	✓				✓				✓				
Bau19	✓				✓				✓		✓		
Hua17					✓	✓	✓	✓	✓				
Zho21					✓	✓	✓	✓	✓				
Bac06	✓				✓				✓				
Još18	✓				✓	✓			✓				✓
Di 14					✓	✓			✓				
Zen15	✓		✓		✓	✓			✓				
Li16	✓				✓	✓			✓				
Vad16					✓	✓			✓				
Qin17	✓				✓	✓			✓				
Xie17	✓				✓	✓			✓				
Xie19	✓	✓			✓	✓			✓				
Zha19		✓	✓	✓	✓	✓			✓				
Yan20	✓		✓		✓	✓			✓				
Sun14	✓				✓	✓	✓		✓				
Sun15	✓	✓	✓		✓	✓	✓		✓				
Sun17	✓		✓	✓			✓		✓				
Xie18a	✓				✓	✓	✓		✓				
Liu18					✓	✓	✓		✓				
Xia17					✓		✓		✓				
Xie18b					✓		✓		✓				
Lin21					✓		✓		✓				
Xia21					✓		✓		✓				
Nüe14	✓								✓	✓	✓		
Sal13									✓	✓			
Eng19	✓								✓	✓			
Gör16	✓	✓							✓	✓	✓		
För21		✓							✓	✓	✓	✓	✓
Gri21					✓				✓			✓	✓
Sch22	✓	✓							✓	✓			✓
Wer23									✓			✓	✓
Vorl. Arbeit	✓	✓	✓	✓		✓	✓	✓	✓	✓		✓	✓

Anhand der gelisteten Arbeiten ist ersichtlich, dass sich bisherige Untersuchungen überwiegend auf eine Optimierung des Kraftstoffverbrauchs beschränken. Weitere Optimierungsziele zur Berücksichtigung realer Betriebsbedingungen wie beispielsweise eine Berücksichtigung der VKM-Starts werden oft vernachlässigt. In diesem Kontext bleibt auch der Mehrwert der Anwendung einer DP gegenüber einer Offline-ECMS im Rahmen der Systemauslegung in der Literatur nicht eindeutig geklärt. Die Arbeiten von [Gri21], [Sch22] und [Wer23] zeigen, dass noch immer ein hoher Forschungsbedarf im Bereich EMS elektrifizierter Fahrzeugantriebe besteht, nicht zuletzt durch das Aufkommen der 48 V-Technologie in den letzten Jahren. [Sch22] bezieht das VKM-Start/Stop-Verhalten in seine Untersuchungen mit ein und entwickelt basierend auf PMP, ECMS und DP eine echtzeitfähige, im realen Fahrzeug einsetzbare EMS mit prädiktiven Eigenschaften. Im Gegensatz zu [Gri21] und [Wer23], die sich auf prädiktive EMS im Bereich der 48 V-Technologie fokussieren, befasst sich [Sch22] jedoch mit Plug-In-Hybriden. Darüber hinaus setzt [Sch22] für den Betrieb des von ihm entwickelten DP-PMP voraus, dass das Fahrgeschwindigkeitsprofil bereits bei Fahrantritt vollständig bekannt ist. Auch bei Ansätzen wie [Bac06] wird die eigentliche Prädiktion des aufkommenden Drehmomentbedarfs entsprechend den Ausführungen aus Kapitel 3.4.3 vorausgesetzt, was im realen Straßenbetrieb keinesfalls durchgehend gewährleistet werden kann.

Insbesondere bei realen Fahrgeschwindigkeitsprofilen ist die Prädiktion aufgrund der vielen Einflüsse (Abbildung 3.5) herausfordernd und meist nur mit einer gewissen Unschärfe möglich. Eine robuste, echtzeitfähige EMS, die auch ohne Prädiktionen quasi-optimales Verhalten bei 48 V-Hybriden im realen Straßenbetrieb unter Berücksichtigung des Start/Stop-Verhaltens der VKM ermöglicht, ist in der Literatur nicht vertreten. Ebenso ist keine generisch einsetzbare Methodik vorhanden, mit der eine solche nichtprädiktive, robuste EMS im Falle des Vorhandenseins prädiktiver Informationen für verschiedene Automatisierungsgrade des Fahrzeugs dynamisch erweitert werden kann. Veröffentlichungen, die mittels datengetriebener Methoden entsprechende Prädiktionen ermöglichen, vernachlässigen oft die Fahrbahnsteigung. Gerade das Fahrbahnsteigungsprofil hat jedoch einen erheblichen

Einfluss auf die optimale Steuerung elektrifizierter Antriebe, da es Rekuperationsmöglichkeiten bietet, die im außerstädtischen Bereich zu erheblichen CO₂-Reduktionspotentialen führen [För21]. Darüber hinaus gibt es Wechselwirkungen zwischen dem Gefälle und den vom Fahrer kontrollierten Größen Fahrzeuggeschwindigkeit und Fahrzeugbeschleunigung [Sil16a]. Dies führt zu der Schlussfolgerung, dass die Fahrbahnsteigung angemessen berücksichtigt werden sollte, vgl. Deufel et al. [1]. Eine detaillierte Analyse der Leistungsfähigkeit sowohl von MC, FFNN und RNN in Bezug auf alle leistungs- und drehmomentrelevanten Größen wurde bisher nicht durchgeführt. Mit dem Grundgedanken an eine möglichst generische und zugleich robuste Anwendbarkeit für jegliche Art von Energiemanagementkonzepten, schließt die vorliegende Arbeit diese Forschungslücke durch detaillierte Untersuchungen, vgl. Deufel et al. [1].

4 Energiemanagementstrategien in der Systemauslegung (48 V-System)

Dieses Kapitel befasst sich mit der Fragestellung, welche EMS bei der Systemauslegung zu verwenden sind. Für die Bestimmung der optimalen EMS für 48 V-Hybride im Rahmen der Systemauslegung wird in [För21, För24] eine Offline-ECMS mit konstantem Äquivalenzfaktor λ verwendet. In Kapitel 4.1 wird zunächst diskutiert, ob eine solche Offline-ECMS zur Bestimmung der optimalen Lösung in der Anwendung auf 48 V-Systeme unter realen Betriebsbedingungen ausreichend ist oder ein alternatives Verfahren bevorzugt werden sollte. Anschließend wird in Kapitel 4.2 die Erweiterung des Simulationsmodells um einen DP-Algorithmus beschrieben. Dabei werden eine geeignete Berücksichtigung der Steuergrößen, die Einführung notwendiger Zustandsgrößen sowie deren geeignete Diskretisierung und die notwendige Definition der Kosten und der unzulässigen Zustände diskutiert. Abschließend erfolgt ein Vergleich der ECMS mit der DP für ein zeitinvariantes System. In Kapitel 4.3 wird anschließend die Anwendung der Verfahren auf zeitvariante Systeme aufgezeigt. Dabei werden beispielhaft die Berücksichtigung des Fahrkomforts, repräsentiert durch die Anzahl an VKM-Starts, und die Dimensionierung der verbauten Batterie untersucht. Abschließend wird ein Zwischenfazit gezogen (Kapitel 4.4).

4.1 Systemauslegung mittels Offline-ECMS

Wie bereits in Kapitel 3.3 beschrieben, kann die Offline-ECMS für die Bestimmung der kraftstoffoptimalen Lösung ohne weitere Optimierungsziele grundsätzlich mit einem konstanten Äquivalenzfaktor λ_0 gefunden werden, wenn

die Vereinfachung aus Formel 3.15 zulässig ist. Hierbei sind die typischen Batterieeigenschaften einer 48 V-Batterie entscheidend. Basierend auf den vorliegenden Kennfeldern zur Abhängigkeit des inneren Widerstands R_i und der Leerlaufspannung U_{OCV} vom Batterieladezustand SOC (Abbildung 4.1, oben) muss geprüft werden, wie sich $\dot{SOC}(P_{bat})$ über verschiedene Ladezustände ändert. Wie in Abbildung 4.1 (unten) zu sehen, liegen die Verläufe für die Änderung des Batterieladezustands \dot{SOC} über der Batterieleistung für verschiedene Ladezustände fast übereinander. Entsprechend betragsmäßig geringe Werte ergeben sich für $\frac{\partial \dot{SOC}}{\partial SOC}$ in Abhängigkeit von Batterieleistung P_{bat} und Batterieladezustand SOC. Dieser Quotient ist entsprechend Formel 3.14 entscheidend für die Änderung des λ -Wertes zur Bestimmung der optimalen Lösung. Die zur Bestimmung der optimalen Lösung entsprechend des PMP notwendigen Änderungen von λ sind somit gering.

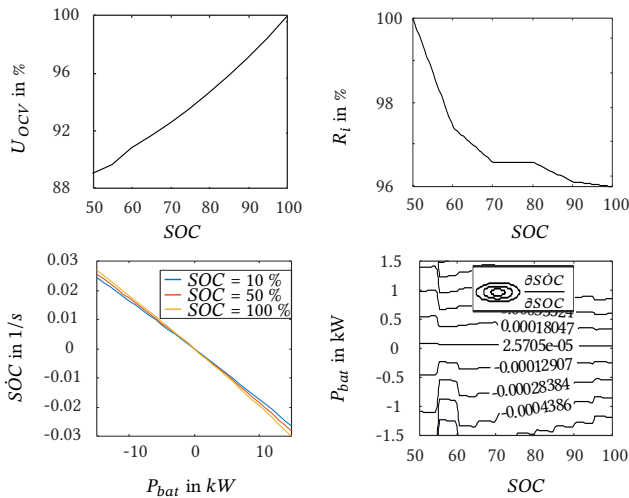


Abbildung 4.1: Analyse der Batterieeigenschaften eines typischen 48 V-Systems. Die Sprünge im Konturplot von $\frac{\partial \dot{SOC}}{\partial SOC}$ zwischen 50 % und 60 % resultieren aus dem Verlauf von U_{OCV} . Die Achsen sind teilweise normiert dargestellt. Der Wert 100 % entspricht der maximalen Leerlaufspannung U_{OCV} bzw. dem maximalen inneren Widerstand R_i in der Darstellung.

Im Rahmen der Untersuchungen werden die Ergebnisse sowohl für ein dynamisches wie ein konstantes λ für eine Vielzahl von Fahrzyklen miteinander verglichen. Im Falle eines dynamischen λ erfolgt stets eine Anpassung entsprechend Formel 3.14, wobei die Werte für $\frac{\partial SOC}{\partial \lambda}$ in Abhängigkeit der auftretenden Batterieleistungen P_{bat} und der Batterieladezustände SOC aus dem errechneten Kennfeld abgerufen werden. Der initiale Äquivalenzfaktor λ_0 wird stets iterativ mittels der SM bestimmt (siehe Kapitel 3.3 und [Ono16]). Nachfolgend sind die resultierenden λ - und SOC-Verläufe für einen exemplarischen Fahrzyklus dargestellt.




Abbildung 4.2: Vergleich eines konstanten gegenüber einem dynamischen Äquivalenzfaktors λ bei der Offline-ECMS mit der Originalbatterie mit 1000 Wh und SOC-abhängigen Eigenschaften. Dargestellt für einen exemplarischen Realfahrzyklus aus Abbildung 2.7.

Man sieht im oberen Plot, dass im betrachteten Fall mittels SM ein Wert von $\lambda_0 \approx 2.52$ bei konstantem λ gewählt wird. Für den Falle des dynamischen λ wird aus der SM ein geringeres λ_0 gewählt, dessen Wertebereich über den betrachteten Fahrzyklus zwischen 2.48 und 2.54 liegt. Dies macht sich auch in den SOC-Verläufen bemerkbar: Wie bereits in Kapitel 3.3 erwähnt, lässt sich λ als Wert der elektrischen Energie interpretieren. So entfernt sich die blaue SOC-Kurve gegenüber der orangenen SOC-Kurve zunächst immer mehr

zu geringeren Batterieladungen, bis zum Schnittpunkt der λ -Verläufe bei ca. $t = 800$ s. Anschließend liegt die blaue λ -Kurve über der orangenen λ -Kurve. Der Einsatz der elektrischen Energie für $800 \text{ s} < t < 1300 \text{ s}$ ist bei einem dynamischen λ höher gewichtet als bei einem konstanten λ , sodass sich die blaue SOC-Kurve der orangenen SOC-Kurve annähert. Die Beträge der resultierenden Kraftstoffverbräuche unterscheiden sich nur geringfügig. Basierend auf den Untersuchungen lässt sich schlussfolgern, dass die Verwendung eines konstanten Äquivalenzfaktors für 48 V-Systeme wie in [För24] umgesetzt, grundsätzlich zulässig ist, um die kraftstoffoptimale Lösung zu erhalten. Für weitere Informationen zum Vergleich eines konstanten mit einem dynamischen Äquivalenzfaktors sei auf [Ono16] verwiesen. [Kim09, Kim12] entwickelte zudem das frei verfügbare Simulationsprogramm *OC-SIM* zum Vergleich eines dynamischen Äquivalenzfaktors mit einer konstanten Implementierung. Aufgrund der ohnehin geringen Abhängigkeiten von U_{OCV} und R_i über dem Batterieladezustand, werden die nachfolgenden Untersuchungen mit konstanten Batterieeigenschaften durchgeführt. Dabei werden die Batterieeigenschaften bei $\text{SOC} = 70 \%$ gewählt, da dies entsprechend den Messungen aus dem Testfahrzeug (Abbildung 5.18) im typischen Arbeitsbereich solcher 48 V-Batterien liegt. Basierend auf dieser Vereinfachung wurde der Energieinhalt der Batterie analog zu [För24] um ein Vielfaches vergrößert ($> 10\,000 \text{ Wh}$), sodass der im Rahmen der jeweiligen Untersuchung tatsächlich nutzbare Energieinhalt der Batterie E_{bat} durch Festlegung der SOC-Grenzen beliebig definiert werden kann. Die konstanten Batterieeigenschaften R_i und U_{OCV} bleiben hiervon unberührt. Die Vervielfachung des Energieinhalts der den Untersuchungen zugrunde liegenden Batterie hat zwar keinen Einfluss auf die optimale EMS, muss jedoch bei der Analyse der SOC-Verläufe berücksichtigt werden.

Es konnte gezeigt werden, dass eine Offline-ECMS mit konstantem Äquivalenzfaktor λ zur Bestimmung der optimalen Lösung in der Anwendung auf 48 V-Systeme unter realen Betriebsbedingungen grundsätzlich ausreichend ist. [Gör16] legt jedoch nahe, dass die Untersuchung von Systemen mit weiteren Zustandsgrößen (neben dem Batterieladezustand SOC) eine Verwendung der DP erfordert. Bei den angestellten Untersuchungen unter realen

Betriebsbedingungen kann diese Einführung weiterer Zustandsgrößen, beispielsweise zur Einschränkung des Start/Stopp-Verhaltens der VKM (siehe Tabelle 4.1) oder zur Berücksichtigung thermischer Effekte notwendig sein. Ebenso ist bei den Ausführungen zum Pontryagin'schen Minimum Prinzip aus Kapitel 3.3 - welches als mathematische Herleitung der Offline-ECMS verstanden werden kann - der SOC-Zustand stets uneingeschränkt. Es ist davon auszugehen, dass die SM bei einer Einschränkung des SOC-Zustandes nicht mehr zu einem optimalen λ_0 führt. Dies kann bei Erreichen der Komponentengrenzen der Batterie auftreten.

Im Folgenden wird deshalb die Offline-ECMS einem Vergleich mit der DP hinsichtlich der Optimalität ihrer Ergebnisse unterzogen. Dies umfasst sowohl eine ausschließliche Berücksichtigung des Batterieladezustands *SOC* als Zustandsgröße, wie auch die Einführung weiterer Zustandsgrößen zur Betrachtung zusätzlicher Optimierungsziele. Ebenso wird eine Einschränkung des nutzbaren Batterieenergieinhalts untersucht. Das bestehende Fahrzeugmodell, welches aus [För21, För24], gekoppelt mit einem Algorithmus zur Offline-ECMS übernommen wurde, wird hierfür entsprechend den Ausführungen im Folgekapitel zunächst um die DP erweitert.

4.2 Erweiterung des Fahrzeugmodells um die DP

Im Rahmen der Arbeit wird das bestehende Modell um einen Lösungsalgorithmus zur DP erweitert. Um den in Kapitel 3.2 beschriebenen Algorithmus inklusive der Rückwärts- und Vorwärtsrechnung (siehe auch Anhang A) anzuwenden, müssen im Modell einige Schnittstellen geschaffen bzw. die Modellarchitekturen entsprechend angepasst werden. Dabei wird die Berechnung aller Störgrößen, die nicht explizit vom DP-Optimierungsproblem abhängig sind, in einem vorgelagerten Skript von der eigentlichen Berechnung entkoppelt. Dies umfasst beim verwendeten rückwärtsrechnenden Modell

vom Rad zur Kurbelwelle das Längsdynamikmodell sowie die Initialberechnung des an der Kurbelwelle ankommenden Drehmomentenbedarfs. Die rechenintensive Bestimmung der auftretenden Verluste über den Antriebsstrang bleiben jedoch Teil des Optimierungsproblems, da diese individuell in Abhängigkeit der verschiedenen Steuergrößen unter Berücksichtigung der jeweiligen Komponentengrenzen bestimmt werden müssen. Schlussendlich wird vom DP-Optimierer nach Beendigung der Rückwärtsrechnung eine optimale Lösung gewählt und dann im Rahmen einer Vorwärtsrechnung angewandt (Zum Ablauf siehe Kapitel 3.2 bzw. Kapitel A). Abschließend wird - wie bereits im ECMS-Modell von [För24] - zusätzlich mit einem vorwärtsrechnenden Fahrzeugmodell eine Plausibilisierung der ermittelten Steuergrößen vorgenommen, bei der überprüft wird, ob mit den ermittelten Drehmomenten das geforderte Fahrzeuggeschwindigkeitsprofil im Rahmen festgelegter Toleranzen erfüllt wird. Nachdem nun die allgemeine Vorgehensweise zur Erweiterung des bestehenden Modells um die DP beschrieben wurde, soll im Folgekapitel die geeignete Berücksichtigung der Steuergrößen des DP-Algorithmus im Modell aufgezeigt werden.

4.2.1 Steuergröße u

Eine Herausforderung stellt die Definition der Steuergröße u dar. So muss diese beim verwendeten Algorithmus der ETH Zürich [Sun09] gleichmäßig diskretisiert zwischen festgelegten Grenzen liegen, gleichzeitig jedoch alle Betriebsmodi (siehe Kapitel 2.1) für jede mögliche Drehmomentanforderung an der Kurbelwelle $T_{req,CS}$ abdecken. Mit der gewählten Implementierung geht die Steuergröße u entsprechend der nachfolgenden Zusammenhänge zur Bestimmung von T_{EM} in das Modell ein (Formel 4.1). Dabei wird auch das maximale generatorische Drehmoment des EM $T_{EM,gen,max}$ benötigt. Die Steuergröße des DP-Algorithmus bewegt sich stets im Wertebereich $u = -1$ bis $u = +1$. Das verbleibende Drehmoment wird dabei von der VKM gestellt (Formel 4.2).

Negative Drehmomente der VKM, welche über das zur Verfügung stehende Schleppmoment der VKM hinaus gehen, werden dabei unter Berücksichtigung der Antriebsstrangverluste von der mechanischen Bremse am Rad aufgebracht.

$$T_{EM} = \begin{cases} u \cdot T_{req,CS}, & \text{für } u > 0 \\ |u| \cdot T_{EM,gen,max}, & \text{für } u \leq 0 \end{cases} \quad (4.1)$$

$$T_{ICE} = T_{req,CS} - T_{EM} \quad (4.2)$$

Wie in Abbildung 4.3 zu sehen, sind mit der entwickelten Definition alle relevanten Bereiche von EM-Kennfeld und VKM-Kennfeld abgedeckt. Dabei sind zur besseren Übersicht zusätzlich das Drehmoment der VKM $T_{ICE,max}$ sowie das maximale motorische Drehmoment der EM $T_{EM,mot,max}$ eingetragen.

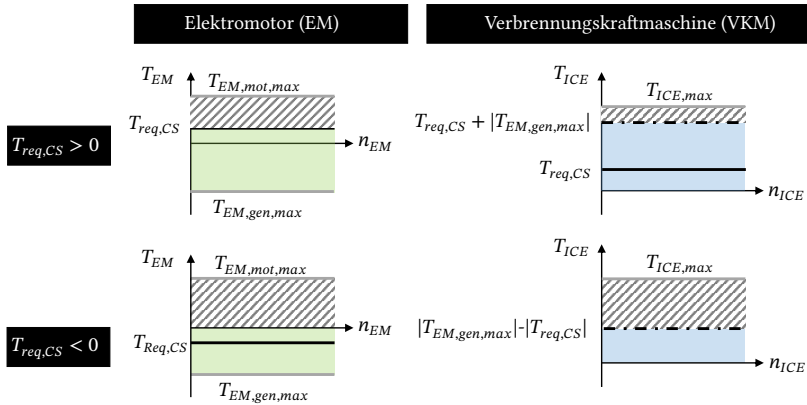


Abbildung 4.3: Visualisierung der berücksichtigten Betriebsmodi basierend auf der festgelegten Definition des Steuergrößenvektors anhand der vereinfachten Kennfelder von EM und VKM. Berücksichtigte Bereiche in grün (EM) bzw. blau (VKM) markiert. Auf die Darstellung des Schleppmoments der VKM wird verzichtet.

Positive Drehmomentanforderung $T_{req,CS}$:

Die gewählte Definition (Formel 4.1) schließt den reinen VKM-Betrieb bzw. den reinen E-Drive Betrieb mit ein. Der Bereich größerer Elektromotormomente als das geforderte Drehmoment aus der Längsdynamik ($T_{EM} > T_{req,CS}$) ist nicht abgedeckt. Ebenso entfällt der Bereich bei dem das maximale Drehmoment der VKM die Summe aus geforderten Drehmoment aus der Längsdynamik und dem maximalen generatorischen Drehmoment des Elektromotors übersteigt ($T_{ICE} > T_{req,CS} + T_{EM,gen,max}$).

Negative Drehmomentanforderung $T_{req,CS}$:

Bei einer negativen Drehmomentanforderung ist die reine Rekuperation mitinbegriffen inkl. Berücksichtigung der mechanischen Bremse. Es fehlt der Betriebsbereich positiver Elektromotormomente ($T_{EM} > 0$). Ebenso werden von der VKM keine Drehmomente gestellt, die größer sind als das Restmoment, was sich vom maximalen generatorischen Drehmoment des EM nach Abzug des rekuperierbaren Drehmoments aus der Längsdynamik ergibt ($T_{ICE} > |T_{EM,gen,max}| - |T_{req,CS}|$).

In allen unberücksichtigten Fällen würde das zusätzliche Drehmoment mechanisch abgebremst bzw. vom zweiten Elektromotor unter Verlusten rekuperiert werden müssen. Im Hinblick auf einen möglichst optimalen Betrieb können diese Betriebsmodi ausgeschlossen werden. Die beschriebene Definition lässt sich sowohl für Motoren in P1- oder P2-Position wie auch in P4-Position anwenden. Auch eine Kombination mehrerer EM ist möglich. Eine Untersuchung der Anzahl der Werte der Steuergröße N_U entfällt. Die Diskretisierung wird analog zur Offline-ECMS gewählt, siehe [För24]. Nachdem nun die geeignete Berücksichtigung der Steuergrößen des DP-Algorithmus im Modell beschrieben wurde, sollen nachfolgend die notwendigen Zustandsgrößen X sowie deren geeignete Diskretisierung diskutiert werden.

4.2.2 Zustandsgröße x

Zur Anwendung einer EMS müssen Zustandsgrößen definiert werden. Zum Auffinden der rein kraftstoffoptimalen Lösung genügt der Batterieladezustand SOC, welcher der Zustandsgröße X_1 zugeordnet wird. Im Rahmen der Arbeit wird für ein möglichst reales Betriebsverhalten zusätzlich das Ein- und Ausschalten der VKM berücksichtigt. Analog zur bestehenden Implementierung der Offline-ECMS wird der VKM-Betrieb sowohl über die harte Randbedingung einer festgelegten VKM-Mindestlaufzeit $\tau_{ICE,min}$, aber auch eine weiche Randbedingung (Bestrafung der Zustandsübergänge) berücksichtigt. Wie in Tabelle 4.1 zu sehen, werden insgesamt drei Zustandsgrößen benötigt. Dabei repräsentiert X_1 den Batterieladezustand SOC, X_2 gibt die VKM-Laufzeit an und X_3 steht für den VKM-Zustand (An/Aus). Während sich die Definition der Zustandsgrößen X_2 und X_3 aus den VKM-Randbedingungen ergeben, muss eine geeignete Diskretisierung für X_1 gefunden werden.

Tabelle 4.1: Definition der Zustandsgrößen im DP-Algorithmus.

Zustandsgröße	Bedeutung	Wertebereich
X_1	Batterieladezustand SOC	$SOC_{min} \dots SOC_{max}$
X_2	VKM-Laufzeit in s	$0, 1, 2, 3 \dots \tau_{ICE,min}$
X_3	VKM-Zustand An/Aus	$0, 1$

Wie in Kapitel 3.3 erwähnt, eignet sich eine Offline-ECMS aufgrund der Äquivalenz zum PMP grundsätzlich, um global optimale Lösungen zu ermitteln. In Kapitel 4.1 konnte außerdem nachgewiesen werden, dass für 48 V-Systeme analog zu den Ausführungen von [För24] ein konstanter Äquivalenzfaktor λ ausreichend ist. Die Bestimmung der optimalen Lösung mittels Offline-ECMS ist entsprechend dem PMP jedoch nur dann möglich, wenn lediglich der Batterieladezustand SOC (hier als X_1 bezeichnet) betrachtet wird und keine zeitvarianten Effekte (beispielsweise durch Erreichen der Batterieladegrenzen) auftreten (vgl. Pontryagin'sches Minimum-Prinzip aus Kapitel 3.3). Dieses Erkenntnis soll im Folgenden zur Bestimmung einer geeigneten Diskretisierung der Zustandsgröße X_1 der DP dienen.

Dabei werden unter Verwendung der Offline-ECMS Handlungsempfehlungen zur Bestimmung einer geeigneten Diskretisierung der Zustandsgröße X_1 der DP anhand einer exemplarischen Systemkonfiguration hergeleitet.

In Tabelle 4.2 sind die prozentualen Abweichungen beim Vergleich der optimalen Kraftstoffverbräuche der Offline-ECMS und der DP für eine Batterie mit einem nutzbaren Energieinhalt von zunächst 475 Wh mit einer Stützstellenzahl von $N_{X_1} = 101$ dargestellt. Der Betrieb der VKM ist uneingeschränkt, die Zustandsgrößen X_2 und X_3 haben also keinen Einfluss.

Tabelle 4.2: Prozentuale Abweichung des ermittelten Kraftstoffbedarfs zwischen Offline-ECMS und DP für eine Batterie mit 475 Wh und einer Stützstellenzahl von $N_{X_1} = 101$. Positive Werte bedeuten einen erhöhten Verbrauch der DP gegenüber der Offline-ECMS. Abweichungen größer 1 % sind grau markiert. Verwendete zwölf Realfahrzyklen entsprechend Abbildung 2.7.

Fahrzyklus	Topologien			
	P1	P2	P14	P24
1	1.80	2.27	1.02	1.21
2	1.88	3.00	1.96	1.96
3	0.90	1.84	1.96	1.33
4	0.46	0.60	0.27	0.21
5	-0.05	0.27	0.06	0.15
6	0.32	0.75	0.41	0.12
7	0.01	0.46	-0.11	0.04
8	0.21	0.34	0.08	0.22
9	0.40	0.54	-0.04	0.12
10	-1.36	-1.5	0.11	-0.4
11	0.19	0.45	-0.20	0.15
12	-0.01	0.17	-0.12	0.22

Bei der Betrachtung einzelner Fahrzyklen zeigt sich, dass der Anspruch an eine maximale Abweichung der DP-Lösung von der Offline-ECMS hinsichtlich Kraftstoffbedarf von $< 1 \%$ (z. B. in [Kim11]) mit Ausnahme von Fahrzyklus 1,2,3 und 10 für alle untersuchten Topologien erfüllt werden kann. Die Fahrzyklen 1-3 sind entsprechend Abbildung 2.7 Stadtfahrten mit insgesamt geringer Dynamik. Daher nutzt die optimale EMS über diese

Fahrzyklen nur wenig des zur Verfügung stehenden Energieinhalts der Batterie. Es ergeben sich bei der DP höhere Verbräuche als bei der ECMS. Bei Fahrzyklus 10, dem Autobahnzyklus mit besonders großer Dynamik, erreicht die optimale EMS teilweise die Batteriegrenzen. Der nutzbare Energieinhalt der Batterie schränkt hier die optimale EMS sowohl bei der DP wie auch bei der Offline-ECMS gleichermaßen ein. Damit treten - wie bei Fahrzyklus 10 - zeitvariante Effekte auf und die Offline-ECMS errechnet keine optimalen Ergebnisse mehr, womit eine Vergleichbarkeit nicht mehr gegeben ist. Es ergeben sich bei der Offline-ECMS höhere Verbräuche als bei der DP (näheres hierzu im Kapitel 4.3.2). Basierend auf weiterführenden Untersuchungen lassen sich folgende, allgemeine Empfehlungen zur Anwendung der DP ableiten.

Für die Lösungsgüte der DP ist entscheidend, wie sehr die Trajektorie eines gegebenen Fahrzyklus den nutzbaren Energieinhalt der Batterie tatsächlich beansprucht. Insbesondere, wenn nur ein kleiner Teil des zur Verfügung stehenden Energieinhalts der Batterie genutzt wird (Fahrzyklen 1-3), kann es zu Abweichungen von der optimalen Lösung kommen, wenn sich ein SOC-Zustandsgitter (Auflösung des SOC-Zustands im Zuge der Diskretisierung) über einen zu großen Energieinhalt der Batterie erstreckt. In diesen Fällen kann entweder die Anzahl der Stützstellen N_{X_1} erhöht oder der berücksichtigte Energieinhalt der Batterie verringert werden. Relevant für die Optimalität der DP ist also nicht alleine die Anzahl der Stützstellen N_{X_1} , sondern der aus der SOC-Diskretisierung resultierende Energieinhalt der Batterie zwischen zwei Batterieladezuständen des Zustandsgitters. Je größer der nutzbare Energieinhalt der Batterie, desto höher ist die notwendige Anzahl der Stützstellen N_{X_1} für dieselbe Lösungsgüte. Um mit einer gegebenen Anzahl an Stützstellen N_{X_1} eine möglichst feine Diskretisierung des Energieinhalts der Batterie zu erreichen, sollte der hinterlegte nutzbare Energieinhalt der Batterie möglichst gering sein, um eine optimale Lösung mittels DP zu bestimmen. Es gilt jedoch sicherzustellen, dass der nutzbare Energieinhalt der Batterie nicht zu gering gewählt wird (vgl. Fahrzyklus 10), sofern eine Beschränkung des nutzbaren Energieinhaltes E_{bat} nicht explizit untersucht werden soll (siehe Kapitel 4.3.2).

Die Ableitung einer allgemein gültigen Regel zur notwendigen Anzahl der Stützstellen N_{X_1} für verschiedene Batteriegrößen und Fahrzyklen ist nicht möglich. Die Ermittlung eines für die Folgeuntersuchungen geeigneten Energieinhalts der Batterie und einer ausreichenden Diskretisierung N_{X_1} fokussiert sich daher auf eine Äquivalenz der DP-Lösung mit der Lösung der Offline-ECMS hinsichtlich der zwölf gewählten Fahrzyklen für die vier untersuchten Topologien. In Abbildung 4.4 sind hierzu exemplarisch für die P2-Topologie Parameterstudien von $N_{X_1} = 51$ bis $N_{X_1} = 751$ für einen nutzbaren Energieinhalt der Batterie von 770 Wh dargestellt. Hierbei sind die prozentualen Verbesserungen im erzielbaren Kraftstoffverbrauch gegenüber der Stützstellenanzahl $N_{X_1} = 51$ aufgetragen. Es zeigt sich, dass mit Ausnahme von *urban high average* (Fahrzyklus 5) bei allen Fahrzyklen 90 % der jeweils maximal erreichbaren, prozentualen Verbesserung im Bereich $N_{X_1} = 401$ bis $N_{X_1} = 501$ erreicht wird. Ab diesem Wertebereich ist insgesamt keine signifikante Verbesserung mehr feststellbar.

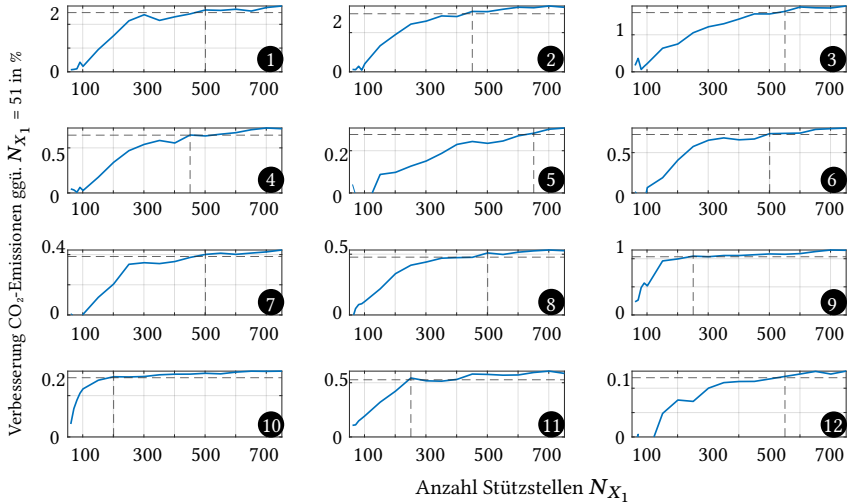


Abbildung 4.4: Prozentuale Verringerung der CO₂-Emissionen bei Erhöhung von N_{X_1} gegenüber $N_{X_1} = 51$ für einen nutzbaren Energieinhalt der Batterie von 770 Wh bei einer P2-Topologie. 90 % Verbesserung sind jeweils markiert. Verwendete Realfahrzyklen entsprechend Abbildung 2.7.

Für die weiteren Untersuchungen wird ein nutzbarer Batterieinhalt von 770 Wh bei $N_{X_1} = 401$ gewählt. Nachdem nun die notwendigen Zustandsgrößen X sowie deren geeignete Diskretisierung diskutiert wurden, wird nun die Definition der Kosten und der unzulässigen Zustände aufgezeigt.

4.2.3 Kostenfunktion C und unzulässige Zustände I

Entsprechend der in Kapitel 3.2 beschriebenen Logik zur DP muss eine Kostenfunktion definiert werden. Diese repräsentiert die instantanen Kosten L_k im Zeitschritt k (Formel 3.6) und wird nachfolgend analog zum verwendeten Algorithmus der ETH Zürich [Sun09] mit C_k bezeichnet. Ebenso müssen für jeden Zeitschritt k die unzulässigen Zustände I_k (engl. *Infeasible States*), also die mit den gegebenen Randbedingungen nicht erreichbaren Lösungen vom Modell ausgegeben werden. Die Kostenfunktion C enthält als Basis den Kraftstoffmassenstrom $\dot{m}_{fuel,k}$ im Zeitschritt k . Analog zur Formel 3.18 aus der ECMS wird die Kostenfunktion unter Berücksichtigung der Zustandsgröße X_3 aus Tabelle 4.1 für den Start bzw. Stopp der VKM um einen additiven Term erweitert, welcher den Faktor kp_{stsp} umfasst (Formel 4.3). Dabei wird der VKM-Zustand zum Zeitpunkt $k-1$ ($X_{3,k-1}$) sowie zum Zeitpunkt k ($X_{3,k}$) herangezogen. Die Kosten C_k sind ausschließlich für die Lösungsfindung des DP-Algorithmus relevant. Der tatsächlich errechnete Kraftstoffmassenstrom zum Zeitpunkt k der VKM $\dot{m}_{fuel,k}$ bleibt hiervon unberührt (Näheres hierzu siehe Kapitel 4.3.1):

$$C_k = \dot{m}_{fuel,k} + \begin{cases} kp_{stsp}, & \text{für } X_{3,k} = 0 \wedge X_{3,k-1} = 1 \\ kp_{stsp}, & \text{für } X_{3,k} = 1 \wedge X_{3,k-1} = 0 \end{cases} \quad (4.3)$$

Lösungen, bei denen die harte Randbedingung einer Mindestlaufzeit von $\tau_{ICE,min}$ nicht eingehalten wird, werden als unzulässige Zustände I als potentielle Lösung ausgeschlossen (Formel 4.4). Hierzu wird zusätzlich die VKM-Laufzeit zum Zeitpunkt k ($X_{2,k}$) herangezogen:

$$I_k = X_{2,k} < \tau_{ICE,min} \wedge X_{3,k} = 0 \wedge X_{3,k-1} = 1 \quad (4.4)$$

Der Parameter μ_{inf} gibt im verwendeten Algorithmus der ETH Zürich [Sun09] die Kosten an, mit denen die unzulässigen Zustände I quantitativ bewertet werden, also mit welchen Kosten diese verbunden sind (vgl. Anhang A). μ_{inf} muss grundsätzlich größer gewählt sein, als der höchste Wert der Cost-To-Go Funktion. Gleichzeitig sollte μ_{inf} so gering wie möglich gewählt werden, um zu vermeiden, dass potentielle Trajektorien im Randbereich aufgrund der hohen interpolierten Kosten für ungültig erklärt werden. Es existieren Ansätze, bei denen die Grenzen des zulässigen Zustandsraumes in einem vorgelagerten Schritt exakt bestimmt werden, um Interpolationsfehler zwischen zulässigen und unzulässigen Zuständen im Randbereich zu reduzieren. So können auch mit einer geringeren Zustandsanzahl optimale Ergebnisse erzielt werden, siehe hierzu [Elb13]. Hierauf liegt jedoch nicht der Schwerpunkt dieser Arbeit, weshalb auf die angegebene Literatur verwiesen wird.

In Abbildung 4.5 sind die prozentualen Verringerungen des Kraftstoffbedarfs für verschiedene Werte von μ_{inf} über die betrachteten Fahrzyklen dargestellt. Es ist grundsätzlich ein möglichst geringer Wert für μ_{inf} anzustreben: Wird $\mu_{inf} = 10^5$ kg/s gewählt, kann bei der gewählten Systemkonfiguration gegenüber $\mu_{inf} = 10^8$ kg/s in einzelnen Fahrzyklen eine Lösung mit einem 0.2 % geringeren Kraftstoffbedarf erzielt werden (Fahrzyklus 1). Vereinzelt treten jedoch auch Verschlechterungen auf, die aus numerischen Fehlern resultieren. Insgesamt kann über die Fahrzyklen eine Verbesserung von 0.05 % erzielt werden. Damit ist die Verringerung des ermittelten Kraftstoffverbrauchs durch eine Variation von μ_{inf} im Vergleich zu den Abweichungen bei einer unzureichenden Stützstellenzahl N_{X_1} (Abbildung 4.2) verhältnismäßig gering. Dennoch empfiehlt sich eine adäquate Auswahl von μ_{inf} , da hier im Gegensatz zu einer Erhöhung der Anzahl an Stützstellen N_{X_1} kein zusätzlicher Rechenaufwand nötig ist, um eine höhere Lösungsgüte zu erzielen.

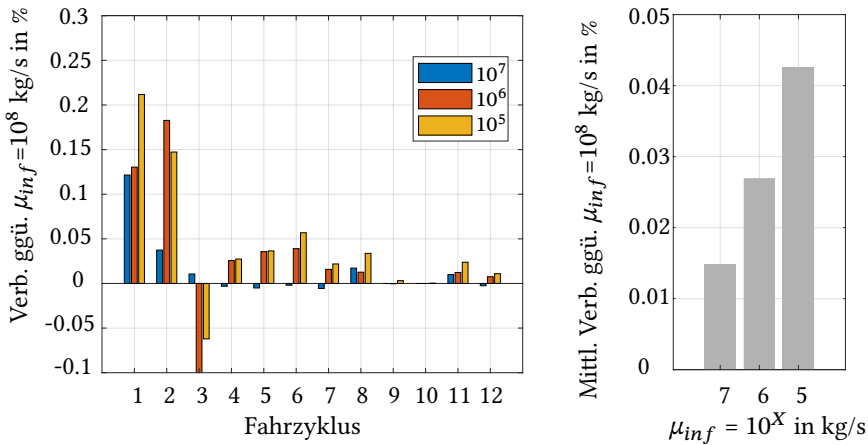


Abbildung 4.5: Einfluss von μ_{inf} : Prozentuale Verringerung des ermittelten Kraftstoffverbrauchs für $\mu_{inf} = 10^7 \text{ kg/s}$, $\mu_{inf} = 10^6 \text{ kg/s}$ und $\mu_{inf} = 10^5 \text{ kg/s}$ gegenüber der Lösung von $\mu_{inf} = 10^8 \text{ kg/s}$. Verwendete Realfahrzyklen entsprechend Abbildung 2.7.

Nachdem nun auch die notwendige Definition der Kosten und der unzulässigen Zustände eingeführt wurden, kann nun ein Vergleich der ECMS mit der DP für ausgewählte Größen erfolgen.

4.2.4 Vergleich DP und Offline-ECMS für ausgewählte Größen

Basierend auf den Erkenntnissen in den vorherigen Kapiteln wird - wenn nicht anders beschrieben - für die nachfolgenden Untersuchungen folgende Parametrierung verwendet (Tabelle 4.3)

Tabelle 4.3: Einstellungen DP-Algorithmus.

Anzahl Stützstellen Zustandsgröße X_1	N_{X_1}	401
Nutzbarer Energieinhalt der Batterie in Wh	E_{bat}	770 Wh
Bewertung der unzulässigen Zustände in kg/s	μ_{inf}	10^5

Die erzielten Kraftstoffverbräuche über die zwölf Realfahrzyklen für das exemplarisch untersuchte D-Segment-Fahrzeug sind in Anhang D gelistet. Die prozentualen Abweichungen der CO₂-Emissionen zwischen DP und Offline-ECMS liegen stets unter 1 % und sind vergleichbar mit Ergebnissen anderer Autoren (z. B. [Kim11]). Die verbleibenden Abweichungen zwischen DP und Offline-ECMS resultieren aus numerischen Fehlern, die an dieser Stelle nicht weiter quantifiziert werden. Neben einer Analyse der resultierenden CO₂-Emissionen wird das entwickelte DP-Modell zusätzlich anhand ausgewählter Größen (Abbildung 4.6) validiert. Diese sind nachfolgend exemplarisch für die P2- und die P24-Topologie dargestellt, da diese aufgrund der zusätzlich verbauten K0-Kupplung zum Abkuppeln des Motors in P2-Position sowie des im Falle der P24-Topologie zusätzlich wirkenden Motors in P4-Position die höchste Komplexität besitzen (Abbildung 2.1). Dabei wird bei der P2-Topologie die in Summe an der Kurbelwelle wirkende Leistung geprüft ($P_{CS,ges}$), bei der P24-Topologie wird aufgrund des Einflusses durch den P4-Motor die direkt am Rad insgesamt aufgebraachte Leistung ($P_{wheel,ges}$) analysiert. Ebenso werden die rekuperierten Leistungen geprüft. Hierbei wird bei der P2-Topologie die vom Elektromotor in P2-Position rekuperierte Leistung untersucht ($P_{CS,recu,EM2}$). Bei der P24-Topologie wird die Summe der von den EM in P2- und P4-Position rekuperierten Leistung betrachtet ($P_{wheel,recu,EM24}$). Es ergibt sich ein hohes Bestimmtheitsmaß R^2 . Die Größen stimmen damit weitestgehend überein. Für beide Fälle ist darüber hinaus der Batterieladezustand SOC gezeigt. Obgleich die Batterieladezustände insgesamt geringe Differenzen aufweisen, ergibt sich über weite Teile ein kleines Offset durch einen vereinzelt unterschiedlichen Einsatz des EM. Hierdurch fällt das Bestimmtheitsmaß etwas geringer aus und es ergeben sich die geringfügigen Unterschiede in den resultierenden CO₂-Emissionen. Die Verläufe im Zeitbereich sind in Anhang D zu finden.

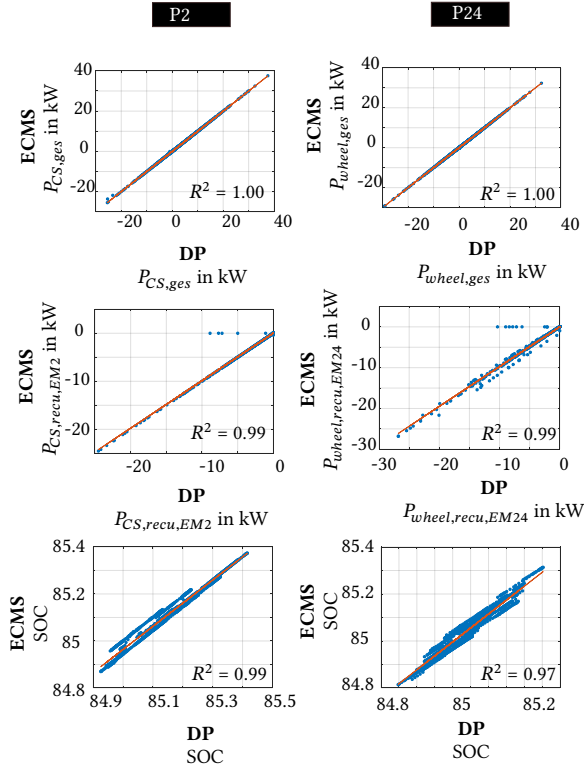


Abbildung 4.6: Visualisierung ausgewählter physikalischer Größen zur Validierung des DP-Modells. Aufgetragen sind die Größen aus dem ECMS-Modell über den Größen des DP-Modells, P2 (links) und P24 (rechts) für $N_{X_1} = 401$ im Realfahrzyklus *urban low mild* (Realfahrzyklus Nr. 3 aus Abbildung 2.7). Zusätzlich ist jeweils das Bestimmtheitsmaß R^2 angegeben.

Bzgl. der topologieabhängigen Rechenzeiten wird das Vielfache der Rechenzeiten der DP gegenüber der Rechenzeit der ECMS bestimmt. Es ist festzuhalten, dass die Rechenzeit der DP entsprechend Abbildung 4.7 für $N_{X_1} = 101$ bei der P1- und P2-Topologie ähnlich sind. Lediglich für die Topologien P14 und P24 sind durch die zusätzliche Steuergröße signifikant erhöhte Rechenzeiten bei der DP feststellbar. Dieser Effekt wurde als *Fluch der Dimensionen* bereits in Kapitel 3.2 beschrieben. Bei $N_{X_1} = 401$ nehmen die Rechenzeiten weiter zu,

sodass die Berechnungen mit der DP deutlich länger benötigen als mit der Offline-ECMS, vgl. Tabelle D.2 im Anhang.




Abbildung 4.7: Vergleich der Rechenzeiten DP ($N_{X_1} = 101$) gegenüber der Offline-ECMS für die untersuchten Topologien. Realfahrzyklen entsprechend Abbildung 2.7.

Entsprechend Formel 3.10 geht mit der Vervierfachung der Anzahl der Stützstellen N_{X_1} bei der DP auch eine Vervierfachung der Rechenzeit bei der DP einher. Diese Verhältnismäßigkeit lässt sich in Abbildung 4.8 insgesamt bestätigen. Auch hier wird ein Faktor bestimmt, der das Vielfache der Rechenzeit der DP mit $N_{X_1} = 401$ Datenpunkten gegenüber der DP mit $N_{X_1} = 101$ Datenpunkten angibt.

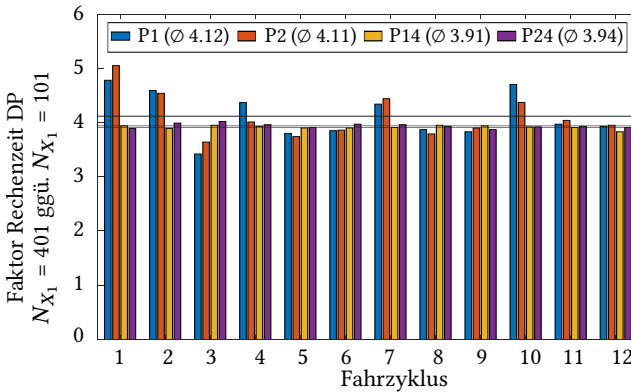


Abbildung 4.8: Vergleich der Rechenzeiten bei der DP für alle untersuchten Topologien mit einer Stützstellenzahl von $N_{X_1} = 401$ gegenüber $N_{X_1} = 101$. Realfahrzyklen entsprechend Abbildung 2.7.

Nachdem nun ein Vergleich der ECMS mit der DP für ausgewählte Größen erfolgt ist, werden ECMS und DP nun auch auf zeitvariante Systeme angewandt. Dabei werden beispielhaft die Berücksichtigung des Fahrkomforts, repräsentiert durch die Anzahl an VKM-Starts, und die Dimensionierung der verbauten Batterie untersucht.

4.3 DP und Offline-ECMS bei zeitvarianten Systemen

In diesem Kapitel wird anhand zweier Anwendungsfälle der Einfluss von zeitvarianten Effekten auf die Optimierungsverfahren DP und Offline-ECMS untersucht.

4.3.1 Berücksichtigung von VKM-Starts

Das Startverhalten der VKM wurde bereits in einigen Studien umfassend untersucht. Dabei hat sich gezeigt, dass der Kraftstoffbedarf für den Start einer VKM stark schwankt (Tabelle 4.4). So werden die realen Motorstartkosten laut [Eng19] neben der Motordrehzahl und der Last beispielsweise auch stark von der Motoröltemperatur beeinflusst. Die Modellierung und Parametrierung zur exakten Abbildung dieses Verhaltens ist entsprechend umfangreich und nicht Fokus dieser Arbeit.

Tabelle 4.4: Kraftstoffbedarf für einen Start der VKM in Gramm (g), zusammengestellt in [S7].

Quelle	Kraftstoffbedarf	Motortyp
[Nüe14]	0.3 g	turboaufgeladener VKM mit 125 kW
[Gör16]	0.5 g	6-Zylinder-Benzinmotor
[Sal13]	0.15-0.4 g	6-Zylinder-Benzinmotor
[Fes09]	0.12-0.165 g	4-Zylinder-Benzinmotor
[Eng19]	0.23-1.3 g	4-Zylinder-Benzinmotor

Aufgrund der Schwankungen des Kraftstoffbedarfs werden keine expliziten Kosten für den VKM-Start herangezogen. Stattdessen werden

die VKM-Starts ausschließlich durch einen Gewichtungsfaktor in der Kostenfunktion (Formel 4.3) analog zur ECMS (Formel 3.18) reduziert. Hierauf basierend errechnet der Optimierer die optimale EMS je nach gewähltem Parameter kp_{stsp} zur Bestrafung des Zustandsübergangs bei einem Start bzw. Stopp der VKM. Es bleibt die Entscheidung der Entwickler, wie viele VKM-Starts durch die entsprechende Wahl von kp_{stsp} letztlich zugelassen werden. Bei einer Betrachtung der Kraftstoffverbräuche muss die Nichtberücksichtigung der Kosten für einen VKM-Start entsprechend beachtet werden.

Der Mehrwert des Einsatzes der DP kann anhand des Zielkonflikts minimale CO₂-Emissionen gegenüber hohem Fahrkomfort (repräsentiert durch die Anzahl an VKM-Starts) aufgezeigt werden. Die Gesamtzahl an Motorstarts wird hierzu durch die Gesamtstrecke des Fahrzyklus geteilt. In Abbildung 4.9 (links) ist das mittels Offline-ECMS unerkannte Potential exemplarisch für die P2-Topologie beim Realfahrzyklus *urban low mild* (Realfahrzyklus Nr. 3 aus Abbildung 2.7) grau eingefärbt. Die Ergebnisse erlauben folgende, allgemeinen Schlussfolgerungen:

- Position I: Ohne Bestrafung der VKM-Starts bestimmen die Offline-ECMS und die DP, wie bereits in Abschnitt 4.2 gezeigt, dieselbe EMS, was sich in gleichen CO₂-Emissionen zeigt. Der blaue und schwarze Marker liegen hier übereinander.
- Position II: Bei mittlerer Bestrafung der VKM-Starts ergibt sich die größte CO₂-Differenz zwischen DP und Offline-ECMS Lösung, obgleich die Offline-ECMS in Einzelfällen auch zu ähnlichen Ergebnissen kommt.
- Position III: Für die maximale Bestrafung beschränkt sich die Anzahl der Motorstarts in beiden Fällen auf $N_{ICE,Starts} = 2$, was für den betrachteten Fahrzyklus 0.43 Motorstarts/km entspricht. Es verbleibt eine merkliche CO₂-Differenz.

Im rechten Teil der Abbildung sind die Verläufe des Drehmoments der VKM an der KW über der Zeit sowohl für die DP wie auch für die Offline-ECMS für

den exemplarisch betrachteten Fahrzyklus dargestellt. Hierbei sind Phasen mit angekuppelter VKM grau markiert.

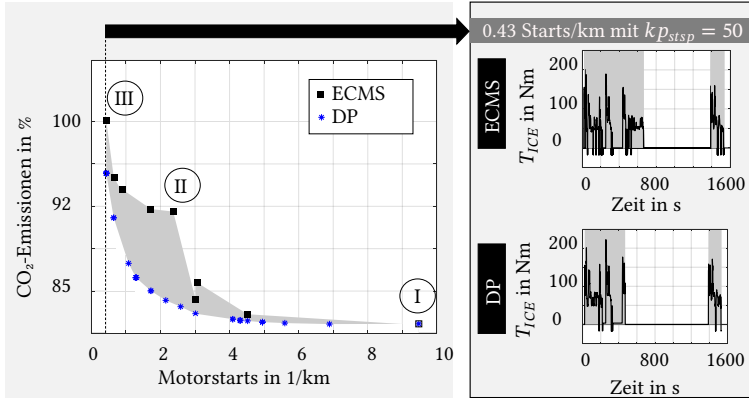


Abbildung 4.9: Zielkonflikt CO_2 -Einsparpotential und Fahrkomfort, repräsentiert durch VKM-Starts beim Realfahrzyklus *urban low mild* (Realfahrzyklus Nr. 3 aus Abbildung 2.7) für eine P2-Topologie (links). Vergleich T_{ICE} für die Offline-ECMS- und DP-Lösung bei 0.43 Starts/km (rechts). Die Achsen sind teilweise normiert dargestellt. Der Wert 100 % entspricht den maximalen CO_2 -Emissionen in der Darstellung.

Es ist deutlich zu erkennen, dass bei der Lösung der Offline-ECMS der Motor insgesamt länger angekuppelt bleibt. Wird das mittlere Drehmoment der VKM $T_{ICE,avg}$ an der Kurbelwelle bestimmt, wird deutlich, dass die VKM im Mittel hier bei geringerer Last betrieben wird ($T_{ICE,avg} = 55 \text{ Nm}$). Der Wirkungsgrad ist entsprechend niedrig. Bei der DP-Lösung hingegen wird die VKM kürzer und mit höherer Last betrieben ($T_{ICE,avg} = 67 \text{ Nm}$). Darüber hinaus sind im Diagramm weniger schwarze Marker als blaue Marker dargestellt. Dies bedeutet, dass für viele VKM-Start-Beschränkungen (durch einen entsprechenden Wert für $k p_{stsp}$) mit der Offline-ECMS keine Lösungen gefunden werden, die CS - also einen ladungserhaltenden Betrieb - einhalten. Es sei abschließend erwähnt, dass durch zusätzliche Maßnahmen der Zielkonflikt einer kraftstoffoptimalen gegenüber einer komfortablen Betriebsweise auch für die Offline-ECMS verbessert werden kann. Dabei wird die zusätzliche Zustandsgröße $E_{stsp,hyst}$ eingeführt, die die maximal zulässige Energie

zur Vermeidung eines VKM-Start/-Stopps definiert. Die zur Vermeidung eines Zustandswechsels zusätzlich aufgebrachte Energie wird dabei integriert und bei Überschreiten einer Schwelle $E_{stsp,hyst,max}$ der Start- bzw. Stoppvorgang freigegeben [För24]. Durch eine passende Kombination von $k_{p_{stsp}}$ und $E_{stsp,hyst,max}$ sind somit bessere Ergebnisse erzielbar (siehe Anhang E). Wie Abbildung E.1 zeigt, bleibt die DP-Lösung auch mit Einführung der zusätzlichen Zustandsgröße $E_{stsp,hyst}$ unerreicht.

Analog zu Abbildung 4.9 verhält es sich bei einer Betrachtung der VKM-Mindestlaufzeit $\tau_{ICE,min}$ in Abbildung 4.10. Bei minimaler VKM-Mindestlaufzeit berechnen sowohl die DP wie auch die Offline-ECMS dieselbe kraftstoffoptimale Betriebsweise. Die CO₂-Emissionen stimmen überein. Mit steigender Laufzeit des VKM weichen die sich ergebenden CO₂-Emissionen bei optimaler Betriebsweise durch die DP deutlich von den resultierenden CO₂-Emissionen durch die Offline-ECMS ab. Die kraftstoffoptimale Lösung der DP kann durch die Offline-ECMS unter Berücksichtigung der entsprechenden VKM-Mindestlaufzeit nicht bestimmt werden.




Abbildung 4.10: CO₂-Emissionen über der VKM-Mindestlaufzeit beim Realfahrzyklus *urban low mild* (Realfahrzyklus Nr. 3 aus Abbildung 2.7) für eine P2-Topologie. Die Achsen sind teilweise normiert dargestellt. Der Wert 100 % entspricht den maximalen CO₂-Emissionen in der Darstellung.

Analog zu den Ausführungen in Kapitel 4.2.4 ist auch hier bei Erhöhung der Anzahl der Gitterpunkte N_{X_1} eine lineare Zunahme der Rechenzeit mit zunehmender VKM-Mindestlaufzeit zu verzeichnen (Abbildung 4.11). So nimmt mit längerer Mindestlaufzeit bei der gewählten Implementierung linear die Anzahl der notwendigen Gitterpunkte von N_{X_2} zu (Tabelle 4.1). Damit erhöht sich ebenso proportional die Rechenzeit nach Formel 3.10. Bei der Offline-ECMS ist hingegen keine direkte Korrelation zwischen Rechenzeit und Mindestlaufzeit festzustellen. Die Rechenzeit ist abhängig davon, wie schnell das Schießverfahren (SM) iterativ die Lösung findet.




Abbildung 4.11: Rechenzeiten über VKM-Mindestlaufzeit DP (links) und Offline-ECMS (rechts) bei Realfahrzyklus *urban low mild* (Realfahrzyklus Nr. 3 aus Abbildung 2.7) für eine P2-Topologie.

Mittels der Zustandsgröße X_2 kann darüber hinaus der Einfluss der VKM-Laufzeit auf den Wirkungsgrad η_{ICE} berücksichtigt werden. Damit ließen sich Rückschlüsse auf die Entwicklung der Temperaturen im Katalysator (KAT) ziehen, sodass weitere, emissionsrelevante Parameter im Energiemanagementproblem berücksichtigt werden können. Die hierfür notwendige detaillierte Modellierung der Erwärmungs- und Reaktionsprozesse ist jedoch nicht Schwerpunkt der Arbeit.

4.3.2 Batteriedimensionierung

Wie in Deufel et al. [2] beschrieben, ist in der Entwicklungsphase für ein 48 V-System neben der Auslegung des Elektromotors mit der zugehörigen Leistungselektronik die Dimensionierung der Li-Ionen-Batterie herausfordernd. Hier gilt es, mit einem möglichst geringen nutzbaren Energieinhalt der Batterie E_{bat} das größte erreichbare Kraftstoffeinsparpotential zu erzielen. Dies resultiert zum einen aus dem grundsätzlichen wirtschaftlichen Interesse an einer möglichst kostengünstigen Batterie, da die Batterie einer der Hauptkostentreiber eines 48 V-Systems ist [Vor19, Car20]. Andererseits steht durch die zunehmende Anzahl anderer elektrischer Energieverbraucher, wie z. B. durch Heizen der Abgasnachbehandlung [Liu20], dem Verbau eines elektrischen Kompressors [Gri19] oder aktiven Fahrwerkssystemen [Tsc19] weniger Energie für das optimale EMS zur Verfügung. Insbesondere bei sehr kleinen nutzbaren Energieinhalten der Batterie kommt es zu zeitvarianten Effekten durch das häufige Erreichen der jeweiligen SOC-Grenzen, wodurch die iterative Bestimmung einer optimalen EMS durch eine Offline-ECMS mittels SM nicht mehr gewährleistet werden kann (siehe auch Kapitel 4.2.2). So kann entsprechend Deufel et al. [2] für eine P14-Topologie die kraftstoffoptimale Lösung der Offline-ECMS bei einem nutzbaren Energieinhalt der Batterie E_{bat} von 100 Wh 30 % vom DP-Optimum abweichen, bei 25 Wh steigt die Abweichung für die zwölf Realfahrzyklen auf bis zu 45 % an. Bei 1000 Wh kann auch die Offline-ECMS eine optimale Lösung bestimmen, da keine SOC-Grenzen erreicht werden.

Im Rahmen der vorliegenden Arbeit wird der Vergleich analog zu den vorangegangenen Untersuchungen für eine P2-Topologie angestellt. Die erzielten Abweichungen zwischen dem minimalen Kraftstoffverbrauch der Offline-ECMS und der DP sind in Abbildung 4.12 jeweils für Batterien mit 25 Wh, 100 Wh und 1000 Wh nutzbarem Energieinhalt über alle zwölf Realfahrzyklen aus Abbildung 2.7 aufgetragen. Die Trends sind äquivalent zur P14-Topologie aus Deufel et al. [2]. Grundsätzlich sind deutliche Abweichungen zwischen

der Lösung der Offline-ECMS und der DP vor allem bei solchen Zyklen feststellbar, bei denen hohe Einsparpotentiale durch das 48V-System bestehen, also in *urban low*- und *urban high*-Zyklen.

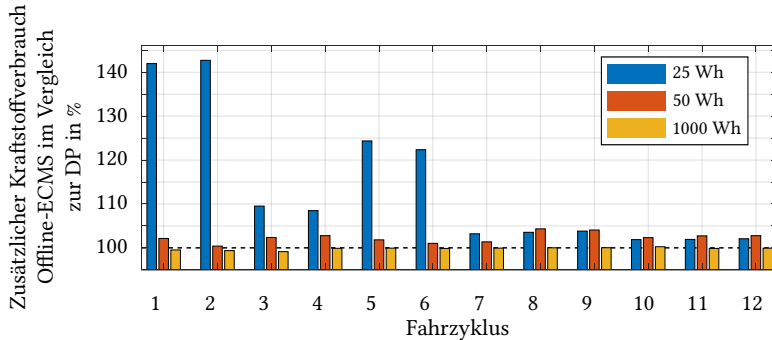


Abbildung 4.12: Relativbetrachtung des minimalen Kraftstoffverbrauchs von Offline-ECMS und DP bei Begrenzung des nutzbaren Energieinhaltes der Batterie E_{bat} auf 25 Wh, 100 Wh und 1000 Wh. 100 % entsprechen jeweils der DP-Lösung. Realfahrzyklen entsprechend 2.7.

Bei Autobahnfahrten mit hohen Leistungsanforderungen (*highway*) sind die Einsparpotentiale durch das 48 V-System entsprechend geringer, da ein VKM-Betrieb im Niedriglastbereich bzw. die Möglichkeit einer rein elektrischen Fahrt seltener auftritt [För21, För24]. Damit macht sich eine suboptimale EMS hier auch deutlich weniger bemerkbar. Grundsätzlich lässt sich jedoch festhalten, dass für Untersuchungen zur Dimensionierung der Batterie bei sehr kleinen Batterien der DP-Ansatz gewählt werden sollte.

In Kapitel 4.1 wurde diskutiert, ob eine Offline-ECMS zur Bestimmung der optimalen Lösung in der Anwendung auf 48 V-Systeme unter realen Betriebsbedingungen grundsätzlich ausreichend ist. Anschließend wurde in Kapitel 4.2 die Erweiterung des Simulationsmodells um einen DP-Algorithmus beschrieben. Dabei wurden die geeignete Berücksichtigung der Steuergrößen, die Einführung notwendiger Zustandsgrößen sowie deren Diskretisierung und ebenso die notwendige Definition der Kosten und der unzulässigen Zustände diskutiert. Anschließend erfolgte ein Vergleich der Offline-ECMS mit der DP für ein zeitinvariantes System. Danach wurde auch eine Anwendung

von Offline-ECMS und DP auf zeitvariante Systeme aufgezeigt. Hierauf aufbauend wird nun abschließend ein Zwischenfazit zum Forschungsfeld *EMS in der Systemauslegung* gezogen.

4.4 Zwischenfazit EMS in der Systemauslegung

Es konnte gezeigt werden, dass für ein 48 V-System die verbreitete Annahme eines konstanten Äquivalenzfaktors bei der Offline-ECMS gültig ist. Außerdem wurde beschrieben, wie ein bestehendes Fahrzeugmodell mit einem generischen DP-Optimierer gekoppelt wird. Dabei wurde zum einen eine geeignete Einbindung der Steuergröße aufgezeigt. Zum anderen wurden insgesamt drei Zustandsgrößen eingeführt, die für die Untersuchungen hinsichtlich einer Berücksichtigung des Start/Stopp-Verhaltens der VKM notwendig sind. Zusätzlich wurden die jeweiligen Definitionen der Kostenfunktion C und der unzulässigen Zustände I vorgestellt. Darüber hinaus wurde die Parametrierung der wichtigsten Einstellparameter wie die Diskretisierung der einzelnen Zustände N_X oder die quantitative Bewertung unzulässiger Zustände μ_{inf} aufgezeigt. Es hat sich gezeigt, dass die Ableitung einer allgemein gültigen Regel zur notwendigen Anzahl der Stützstellen N_{X_1} für verschiedene nutzbare Energieinhalte der Batterie und Fahrzyklen nicht möglich ist. Daher wurde für die Folgeuntersuchungen ein Energieinhalt der Batterie und eine Diskretisierung gewählt, mit der eine Äquivalenz der DP-Lösung mit der Lösung der Offline-ECMS hinsichtlich der zwölf gewählten Fahrzyklen für die vier untersuchten Topologien aufgezeigt werden kann. Die Ergebnisse zeigen, dass ohne zeitvariante Effekte sowohl mit der DP wie auch mit der Offline-ECMS im Rahmen der Systemauslegung die kraftstoffoptimale Lösung bestimmt wird. Die Rechenzeiten bei der DP liegen aufgrund der notwendigen Diskretisierung der Zustände und dem Fluch der Dimensionen jedoch höher als bei der Offline-ECMS: Eine Erhöhung der Anzahl der Gitterpunkte ruft dabei einen proportionalen Anstieg der Rechenzeit bei der DP hervor. Bei mehrmotorigen Konzepten steigt die Rechenzeit der DP durch die zusätzliche Steuergröße überproportional an. Zum Auffinden der rein kraftstoffoptimalen EMS ist

daher die Offline-ECMS zu empfehlen. Treten jedoch zusätzlich zeitvariante Effekte auf, wie beispielsweise ein eingeschränktes VKM-Verhalten zur Abbildung realer Betriebsbedingungen oder werden kleine Batterien verbaut, sollte die DP verwendet werden. Es gilt kritisch festzuhalten, dass im Rahmen der Untersuchungen zwar der Einfluss einer Beschränkung der VKM-Starts auf den Kraftstoffbedarf bzw. die CO₂-Emissionen berücksichtigt wird. Aufgrund der beschriebenen Schwankungen (Abbildung 4.4) wird dabei jedoch der zusätzlich notwendige Kraftstoff für den jeweiligen VKM-Start nicht berücksichtigt. In diesem Zuge wird auch ein Mehrverbrauch bei kaltem Motor bzw. die Verringerung des Kraftstoffbedarfs bei einem warmen Motor nicht näher betrachtet.

5 Energiemanagementstrategien im realen Fahrbetrieb (48 V-System)

Nachdem das Forschungsfeld *EMS in der Systemauslegung* im vorherigen Kapitel abgeschlossen wurde, befasst sich dieses Kapitel mit EMS im realen Fahrbetrieb. Im Fokus dieser Arbeit steht die Entwicklung einer robusten, onlinefähigen, optimalen EMS. Im Gegensatz zu anderen Onlinekonzepten wie beispielsweise von [Bac06, Wah15, Bau19], kann die im Folgenden vorgestellte Online-ECMS auch ohne Kenntnis des zukünftigen Fahrgeschwindigkeitsprofils appliziert werden. Durch die Unabhängigkeit von Zukunftsprognosen ist eine robuste Einsetzbarkeit gewährleistet. Dabei wird im Rahmen der Arbeit vorausgesetzt, dass die für den Betrieb notwendige Sensorik und Aktuatorik zuverlässig funktioniert. Ebenso muss die Kommunikation im Bussystem verlässlich operieren. Darüber hinaus muss der Ausfall des Systems entsprechend abgesichert und außerdem eine Echtzeitfähigkeit sichergestellt sein. Letzteres wird im Rahmen der Arbeit in Kapitel 5.3 betrachtet. Durch eine entsprechende Auslegung der Online-ECMS kann auch eine Fehlertoleranz gegenüber stochastischen Störungen wie beispielsweise durch Wind, durch das Öffnen von Fenstern und Schiebedach, Fahrbahnoberflächenänderungen aber auch systematische Fehler (Änderung der Fahrzeugmasse, fehlerhafte Modellparameter) gewährleistet werden. Die Online-ECMS ermöglicht damit eine zuverlässige Bestimmung der Drehmomentverteilung bei gleichzeitiger Sicherstellung der Ladungserhaltung (CS). Außerdem wird eine ausreichend schnelle Berechnung nachgewiesen. Der Grundgedanke der im Rahmen dieser Arbeit vorgestellten robusten, nicht-prädiktiven Online-ECMS wurde bereits in Deufel et al. [2] dargestellt und exemplarisch anhand eines P14-Hybriden umgesetzt. Nachfolgend wird die Methodik auf die verschiedenen Topologien angewandt und dabei einigen

tiefergehenden Analysen unterzogen. Dies umfasst neben der zusätzlichen Betrachtung des Start/Stopp-Verhaltens der VKM, eine Betrachtung der Echtzeitfähigkeit und die umfassende Validierung. In Kapitel 6 wird ergänzend ein Ausblick zum Potential einer prädiktiven Online-ECMS gegeben.

Die Methodik ist in Abbildung 5.1 zusammengefasst und wird in Kapitel 5.1 beschrieben. Dabei muss entsprechend Kapitel 5.1.1 basierend auf den λ_0 -Werten aus der Offline-ECMS für den individuellen Fahrzyklus ein gemittelter Äquivalenzfaktor ($\lambda_{0,avg}$) bestimmt werden. Anschließend muss entsprechend Kapitel 5.1.2 ein Proportionalitätsfaktor k_{pSOC} eingeführt werden, welcher eine (Ent-)ladung der Batterie bestraft. Die Ergebnisse sind in Kapitel 5.1.3 gelistet. Anschließend wird die entwickelte Online-ECMS auf Messdaten aus Realfahrten eines Testfahrzeugs angewandt (Kapitel 5.2). Der verwendete *Datensatz zur Validierung* wird dabei vorgestellt (Kapitel 5.2.1) und das Modell auf das Testfahrzeug parametriert (Kapitel 5.2.2). Damit erfolgt eine Validierung der entwickelten Online-ECMS und die Ableitung von Handlungsempfehlungen hinsichtlich der EMS des Testfahrzeugs (Kapitel 5.2.3). Anschließend wird eine mögliche Implementierung der vorgestellten Online-ECMS im realen Fahrzeug aufgezeigt sowie die Echtzeitfähigkeit des Ansatzes nachgewiesen (Kapitel 5.3). Nachfolgend wird ein Zwischenfazit gezogen (Kapitel 5.4).

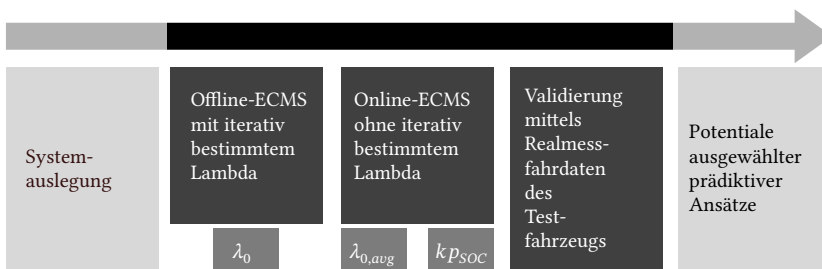


Abbildung 5.1: Methodik zur Auslegung einer robusten, echtzeitfähigen Online-ECMS.

5.1 Robuste, nichtprädiktive Online-ECMS

Wie bereits in Deufel et al. [2] beschrieben, wird zunächst als Basis für die robuste, echtzeitfähige Online-ECMS topologiespezifisch das arithmetische Mittel der Äquivalenzfaktoren aller Fahrzyklen bestimmt und als $\lambda_{0,avg}$ bezeichnet. Hierbei wird angenommen, dass der reale Fahrbetrieb durch eine Gleichgewichtung aller Fahrzyklen repräsentiert wird. Ohne weitere Maßnahmen ist das CS-Verhalten im Onlinebetrieb jedoch nicht sichergestellt. Die aus den dann zunächst unpassenden Äquivalenzfaktoren resultierenden SOC-Trajektorien führen je nach Fahrzyklus zu einer übermäßigen Ladung oder Entladung der Batterie (siehe Abbildung 3.3, rechts). Eine verbreitete Maßnahme zur Vermeidung dieses Verhaltens ist die Einführung eines zusätzlichen Strafterms bei der Berechnung des effektiv in der Online-ECMS wirkenden Äquivalenzfaktors λ_{eff} . Dabei wird der Wert der elektrischen Energie in Abhängigkeit von der Abweichung des tatsächlichen SOC vom Startladezustand (ΔSOC_{CS}) entweder erhöht oder verringert. ΔSOC_{CS} gibt dabei die Differenz des Batterieladezustands SOC zum Referenzladezustand für einen ladungserhaltenden Betrieb, also dem Initialzustand zu Beginn des Fahrzyklus SOC_{init} an (Formel 5.1):

$$\Delta SOC_{CS}(t) = SOC(t) - SOC_{init} \quad (5.1)$$

Nach [Gör16, Ena17] ist die Bestrafung über eine kubische Funktion einer proportionalen vorzuziehen: Sie erlaubt kleine Abweichungen vom Referenzladezustand, große Abweichungen werden hingegen stark bestraft. Da beim 48 V-Hybrid typischerweise ein ladungserhaltender Betrieb (CS) angestrebt wird, entspricht der Referenzladezustand dem Start- bzw. Endladezustand der Batterie. Wie in Formel 5.2 dargestellt, setzt sich der Strafterm aus dem Straffaktor kp_{SOC} multipliziert mit der kubischen Abweichung von SOC zusammen, die als $\Delta SOC_{CS}(t)^3$ bezeichnet wird, vgl. Deufel et al. [2]:

$$\lambda_{eff}(t) = \lambda_{0,avg} - kp_{SOC} \cdot \Delta SOC_{CS}(t)^3 \quad (5.2)$$

Anstatt der Abweichung der Batterieladung gegenüber dem Initilladezustand ΔSOC_{CS} lässt sich auch eine Energiemenge angeben, wie sehr die Batterie gegenüber dem Initialzustand geladen ist. Diese Abweichung der Batterieenergie im Vergleich zum Initialzustand wird als ΔE_{CS} bezeichnet, die Endenergieabweichung der Batterie zum Fahrtende entsprechend mit $\Delta E_{CS,end}$. Zur Herleitung von $\Delta E_{CS,end}$ sei auf Formel 5.4 verwiesen. Basierend auf den im Fahrversuch mit einem aktuellen Hybridfahrzeug gemessenen Batterieendabweichungen $\Delta E_{CS,end}$ (siehe auch Abbildung 5.18) wird die Anforderung definiert, dass die Endabweichung des Energiegehalts der Batterie zum Fahrtende $\Delta E_{CS,end}$ innerhalb des Wertebereichs ± 100 Wh liegen sollte. Es wird weiterhin davon ausgegangen, dass der reale Fahrbetrieb durch eine gleiche Gewichtung aller gegebenen Fahrzyklen dargestellt wird. Basierend hierauf muss in einem nächsten Schritt jeweils ein geeignetes k_{pSOC} gefunden werden.

Nachdem nun der effektiv in der Online-ECMS wirkende Äquivalenzfaktor λ_{eff} eingeführt wurde, wird im Folgenden zunächst auf die Bestimmung des gemittelten Äquivalenzfaktors eingegangen.

5.1.1 Basislambda für Online-ECMS

Zur Auslegung einer solchen robusten, nichtprädiktiven Online-ECMS werden im ersten Schritt iterativ die optimalen λ_0 -Werte mittels der Offline-ECMS analog zu Abbildung 3.3 über alle zwölf repräsentativen Fahrzyklen (Abbildung 2.7) ermittelt. Diese jeweils optimalen λ_0 -Werte sind für alle untersuchten Topologien in Abbildung 5.2 bzw. in Anhang F dargestellt. Wie bereits in den Grundlagen erwähnt, lässt sich der Äquivalenzfaktor λ grundsätzlich als Wert der elektrischen Energie bzw. als Gesamtwirkungsgrad des hybrid-elektrischen Antriebsstrangs deuten. Da die elektrische Energie bei einem P1-Hybriden aufgrund des stets wirkenden Schleppmomentes der VKM am

Ineffizientesten eingesetzt wird, liegen hier auch die geringsten Äquivalenzfaktoren vor. Für die betrachteten Fahrzyklen ergibt sich der für den energieoptimalen Betrieb der ECMS gewählte, durchschnittliche Äquivalenzfaktor für eine P1-Topologie zu $\lambda_{0,avg,P1} = 2.55$. Durch die Verwendung der K0-Kupplung (P2) erhöht sich die Effizienz deutlich ($\lambda_{0,avg,P2} = 2.90$). Am Effizientesten arbeitet das Hybridsystem jedoch durch Verwendung eines zusätzlichen EM auf P4-Position. Hierdurch kann ohne zusätzliche Antriebsstrangverluste/Schleppverluste elektrisch gefahren bzw. elektrische Energie rekuperiert werden. So ergibt sich für einen P14-Hybrid ein $\lambda_{0,avg,P14} = 3.10$. Das zusätzliche Einsparpotential durch die Verwendung der K0-Kupplung (P24) ist begrenzt (P24: $\lambda_{0,avg,P24} = 3.11$). Diese Beobachtungen decken sich auch mit den Ergebnissen aus [För24].

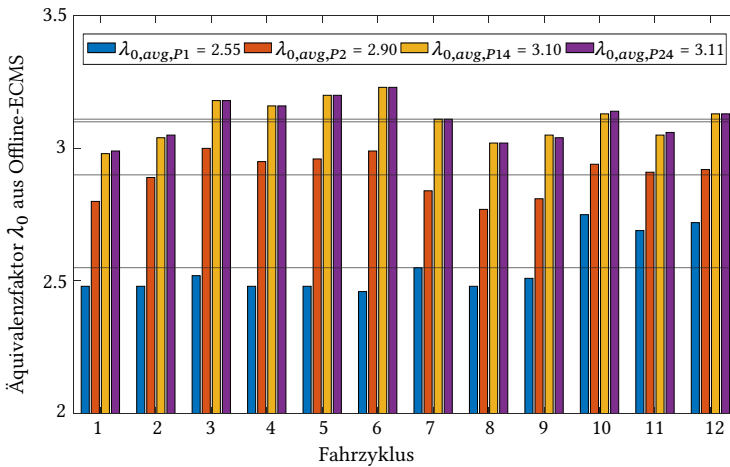


Abbildung 5.2: Vergleich der Äquivalenzfaktoren der robusten, echtzeitfähigen Online-ECMS für die Topologien P1,P2,P14, P24. Realfahrzyklen entsprechend Abbildung 2.7.

Nachdem nun die Bestimmung des gemittelten Äquivalenzfaktors ($\lambda_{0,avg}$) basierend auf λ_0 aus der Offline-ECMS für den individuellen Fahrzyklus aufgezeigt wurde, wird im Folgekapitel der Proportionalitätsfaktor k_{pSOC} zur Bestrafung der (Ent-)ladung der Batterie näher beschrieben.

5.1.2 Straffaktor kp_{SOC} für Online-ECMS

Die Studien zur Auslegung der Online-ECMS für alle untersuchten Topologien sind in Anhang F vorgestellt. In diesem Abschnitt werden exemplarisch die Analysen für einen P1-Hybriden dargestellt, da ein solcher in Kapitel 5.2 zur Validierung der Strategie verwendet wird. Wie in Abbildung 5.3 ersichtlich, steigen die CO_2 -Emissionen mit zunehmendem kp_{SOC} über alle zwölf Realfahrzyklen an.

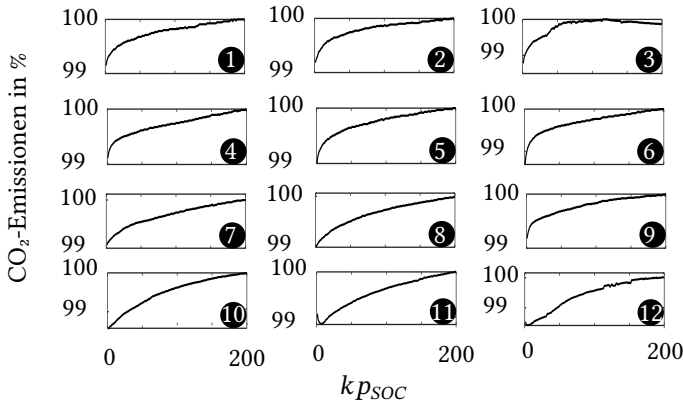


Abbildung 5.3: Visualisierung der CO_2 -Emissionen für eine P1-Topologie für die zwölf Realfahrzyklen entsprechend Abbildung 2.7: Parameterstudie für die Online-ECMS bei kp_{SOC} von 0 bis 200. Die Achsen sind teilweise normiert dargestellt. Der Wert 100 % entspricht den jeweils maximalen dargestellten CO_2 -Emissionen.

Die Differenz zwischen maximalem (SOC_{max}) und minimalem Ladezustand (SOC_{min}) wird mit $\Delta SOC_{min,max}$ bezeichnet (Formel 5.3). Damit lässt sich auch qualitativ der genutzte Energieinhalt bestimmen:

$$\Delta SOC_{min,max} = SOC_{max} - SOC_{min} \quad (5.3)$$

Es zeigt sich, dass $\Delta SOC_{min,max}$ für alle Fahrzyklen entsprechend Abbildung 5.4 mit zunehmendem kp_{SOC} abnimmt. Grund ist die Bestrafung der Abweichung ΔSOC_{CS} nach Formel 5.2. Die Hybridfunktionalität wird mit zunehmendem kp_{SOC} entsprechend eingeschränkt.

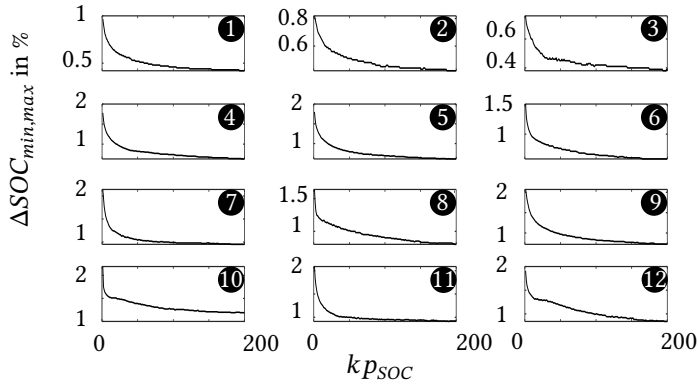


Abbildung 5.4: Visualisierung des genutzten Energieinhalts der Batterie, ausgedrückt durch $\Delta SOC_{min,max}$ für eine P1-Topologie für die zwölf Realfahrzyklen entsprechend Abbildung 2.7: Parameterstudie für die Online-ECMS bei kp_{SOC} von 0 bis 200.

Unter Berücksichtigung von Formel 2.10 kann die gegenüber dem Referenzladezustand in der Batterie gespeicherte Energie bestimmt werden (Formel 5.4):

$$\Delta E_{CS} = \int dE_{bat} \quad (5.4)$$

Die Endenergieabweichung zum Ende des Fahrzyklus $\Delta E_{CS,end}$ (Abbildung 5.5) konvergiert mit zunehmendem kp_{SOC} zur rekuperierten Energie der abschließenden Bremsung des jeweiligen Fahrzyklus. Grund hierfür ist, dass eine Ladung der Batterie im Rekuperationsfall auch bei sehr hohen Werten für kp_{SOC} stets zugelassen wird. Grundsätzlich führt ein im Zuge der Rekuperation erhöhter Ladezustand zu einem erhöhten ΔSOC_{CS} , was bei einem hohen kp_{SOC} zu einem geringen Wert für λ_{eff} führt. Dadurch wird der Wert der elektrischen Energie im Optimierungsproblem grundsätzlich verringert (Formel 3.11 bzw. Formel 3.16). Es sei an dieser Stelle darauf hingewiesen, dass negative Werte für λ_{eff} bei der von [För24] übernommen Implementierung einer ECMS nicht zugelassen werden:

$$\lambda_{eff} = \begin{cases} \lambda_{eff}, & \text{für } \lambda_{eff} > 0 \\ 0, & \text{für } \lambda_{eff} < 0 \end{cases} \quad (5.5)$$

Darüber hinaus gilt im Rekuperationsfall für den Kraftstoffmassenstrom \dot{m}_{fuel} :

$$\dot{m}_{fuel} = 0 \quad (5.6)$$

Im Hinblick auf die Basisfunktion der ECMS (Formel 3.17) wird während der Rekuperation somit auch bei sehr großen Werten für kp_{SOC} und damit verbundenen geringen λ_{eff} stets ein Betrieb mit maximal generatorischem Betrieb (also der betragsmäßig höchsten Batterieleistung P_{bat}) gewählt, da diese den geringsten äquivalenten Kraftstoffmassenstrom \dot{m}_{eqv} aufweist. In allen anderen Situationen führt der hohe kp_{SOC} -Wert hingegen dazu, dass (Ent-)ladevorgänge sukzessive unzulässig sind. Falls $\lambda_{0,avg}$ im Vergleich zum individuell passenden λ_0 aus der Offline-ECMS deutlich geringer ausfällt, so verläuft der Batterieladezustand SOC insgesamt in Bereichen geringerer Ladung. Dies kann dazu führen, dass trotz auftretender Schlussbremsung ein negatives $\Delta E_{CS,end}$ verbleibt.

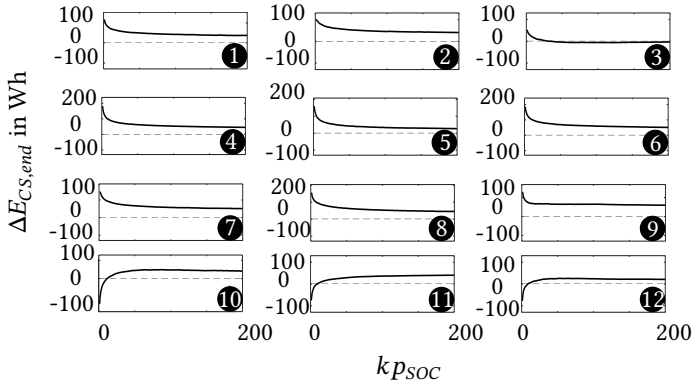


Abbildung 5.5: Visualisierung der Endenergieabweichung $\Delta E_{CS,end}$ in Wh für eine P1-Topologie für die zwölf Realfahrzyklen entsprechend Abbildung 2.7: Eine Endenergieabweichung zum Ende des Fahrzyklus von $\Delta E_{CS,end} = 0$ ist mit einer gestrichelten Linie gekennzeichnet. Parameterstudie für die Online-ECMS bei kp_{SOC} von 0 bis 200.

Entsprechend Abbildung 5.6 lässt sich für jeden Fahrzyklus aus Abbildung 5.5 ein $kp_{SOC,CS}$ (im weiteren Verlauf der Arbeit kurz kp_{SOC} bezeichnet) bestimmen, welches notwendig ist um die Randbedingungen hinsichtlich eines ladungserhaltenden Betriebs ($-100 \text{ Wh} < \Delta E_{CS,end} < 100 \text{ Wh}$) einzuhalten.




Abbildung 5.6: Exemplarische Visualisierung der Endenergieabweichung $\Delta E_{CS,end}$ in Wh für einen Realfahrzyklus aus Abbildung 5.5 zur Identifikation von $kp_{SOC,CS}$ (im weiteren Verlauf der Arbeit kurz: kp_{SOC}). Der zulässige Bereich für $\Delta E_{CS,end}$ ist eingetragen.

Für die Parametrierung der nichtprädiktiven EMS wird das über alle Fahrzyklen höchste, notwendige kp_{SOC} ausgewählt, um eine robuste Einsetzbarkeit zu garantieren. Bei einer bekannten Route könnte kp_{SOC} zunächst geringer gewählt werden, um einen höheren Energieinhalt der Batterie zu nutzen und somit eine weitere CO_2 -Reduktion zu erreichen. Zum Ende der Route muss kp_{SOC} dann wieder vergrößert werden, um ladungserhaltenden Betrieb (CS) sicherzustellen. Da dies jedoch im Widerspruch zu einer robusten Einsetzbarkeit steht, wird dieser Ansatz nicht weiter verfolgt. Die Untersuchungen hinsichtlich der Potentiale ausgewählter prädiktiver Ansätze beschränken sich auf Kapitel 6.

Nachdem neben dem gemittelten Äquivalenzfaktor ($\lambda_{0,avg}$) nun zusätzlich der Proportionalitätsfaktor kp_{SOC} zur Bestrafung der (Ent-)ladung der Batterie eingeführt wurde, werden nachfolgend die Ergebnisse der Online-ECMS gegenüber der Offline-ECMS bei der Anwendung auf die zwölf Realfahrzyklen aus Abbildung 2.7 aufgezeigt.

5.1.3 Ergebnisse

Die Einstellparameter ($\lambda_{0,avg}$ und kp_{SOC}) für die vorgestellte, nichtprädik-
tive Online-ECMS für alle untersuchten Topologien sind in Tabelle 5.1 ge-
listet. Zusätzlich ist die jeweils mittlere CO_2 -Abweichung der Online-ECMS
zum theoretischen Optimum (Offline-ECMS) über alle zwölf Fahrzyklen ein-
getragen ($\Delta_{CO_2,avg}$). Es zeigt sich, dass im Mittel Verschlechterungen von
bis zu 1.01 % (P24-Topologie) gegenüber der theoretischen, global kraftstoff-
optimalen EMS über alle zwölf Realfahrzyklen zu erwarten sind.

Tabelle 5.1: Finale Parametrierung Online-ECMS für P1-, P2-, P14- und P24-Topologie unter Ver-
wendung der zwölf Realfahrzyklen entsprechend Abbildung 2.7.

	Topologien			
	P1	P2	P14	P24
$\lambda_{0,avg}$	2.55	2.90	3.10	3.11
kp_{SOC}	12	85	115	115
$\Delta_{CO_2,avg}$ in %	0.02	0.56	0.97	1.01

Da beim P1-Hybrid bereits ein geringer Straffaktor kp_{SOC} von 12 ausrei-
chend ist, um einen ladungserhaltenden Betrieb zu ermöglichen, sind die
ermittelten Verbräuche besonders nah an der global kraftstoffoptimalen
Lösung. Durch numerische Fehler liegen die errechneten Verbräuche in *ur-
ban low* (Fahrzyklen 1-3) und *urban high* (Fahrzyklen 4-6) sogar etwas unter
dem globalen Optimum (Abbildung 5.7). Diese numerischen Fehler liegen
mit bis zu 0.4 % - im Vergleich zu den maximalen Verschlechterungen der
Online-ECMS gegenüber der Offline-ECMS von bis zu 1.6 % - vergleichsweise
hoch. Dies lässt sich durch das Zusammenspiel zweier Effekte erklären:
Zum einen ermöglicht eine onlinefähige Implementierung der ECMS mittels
SOC-abhängiger Regelung des Äquivalenzfaktors ein nahezu optimales Be-
triebsverhalten, was sich auch mit der Literatur deckt (vgl. Kapitel 3.1). So
beschreibt [Ono11] das Verhalten als *quasi-optimal* und stellt Abweichungen
zum globalen Optimum in der Größenordnung 1-2 % fest. Zum anderen
stellt eine Online-ECMS den ladungserhaltenden Betrieb (CS) nur in einem
bestimmten Toleranzrahmen von $-100 \text{ Wh} < \Delta E_{CS,end} < +100 \text{ Wh}$ sicher (vgl.
Abbildung 5.6). Für eine Vergleichbarkeit mit der Offline-ECMS müssen die

ermittelten Verbräuche daher korrigiert werden, was durch die im späteren Verlauf der Arbeit eingeführten Formeln 5.13 und 5.14 erfolgt. Aufgrund der hierbei gemittelten Wirkungsgrade über den Fahrzyklus ist die Korrektur der CO_2 -Emissionen der Online-ECMS mit einer gewissen Unschärfe verbunden. Eine tabellarische Auflistung der Ergebnisse ist darüber hinaus in Anhang F zu finden.




Abbildung 5.7: Ergebnisse der Online-ECMS im Vergleich zur global optimalen Lösung (Offline-ECMS) hinsichtlich CO_2 -Emissionen. Negative Werte bedeuten eine Verschlechterung der Online-ECMS gegenüber der Offline-ECMS. Realfahrzyklen entsprechend Abbildung 2.7.

Der bekannte Zielkonflikt CO_2 -Einsparpotential gegenüber VKM-Start/Stopps aus Kapitel 4.3.1 ist in Abbildung 5.8 exemplarisch für die P2-Topologie beim Realfahrzyklus *urban low mild* (Realfahrzyklus Nr. 3 aus Abbildung 2.7) dargestellt. Zur Berücksichtigung des Start/Stop-Verhaltens der VKM wird auch bei der Online-ECMS der sich entsprechend Formel 3.18 ergebende, äquivalente Kraftstoffbedarf unter Berücksichtigung der VKM-Starts $\dot{m}_{eq,ICE,stp}$ herangezogen. Dieser ergibt sich aus dem Produkt von äquivalentem Kraftstoffmassenstrom \dot{m}_{eq} und dem Parameter $k_{p,stp}$. Die Abbildung zeigt, dass eine Online-ECMS den Zielkonflikt weniger optimal löst, als die vorgestellten

Verfahren zur Identifikation des theoretischen Optimums Offline-ECMS und DP. Dennoch ist deutlich ersichtlich, dass mit der vorgestellten Online-ECMS auch im Onlinebetrieb eine adäquate Einschränkung des Start/Stopp-Verhaltens der VKM möglich ist. Zudem wäre auch hier grundsätzlich eine Erweiterung um die zusätzliche Zustandsgröße $E_{stp,hyst}$ analog zu Anhang E denkbar, um den aufgezeigten Zielkonflikt besser zu lösen.




Abbildung 5.8: Zielkonflikt CO₂-Einsparpotential und Fahrkomfort, repräsentiert durch VKM-Starts beim Realfahrzyklus *urban low mild* (Realfahrzyklus Nr. 3 aus Abbildung 2.7) für eine P2-Topologie für die Online-ECMS im Vergleich zu den Lösungen der Offline-ECMS und der DP aus der Offline-Optimierung. Die Achsen sind teilweise normiert dargestellt. Der Wert 100 % entspricht den maximalen CO₂-Emissionen in der Darstellung (Online-ECMS).

Die entwickelte Online-ECMS wurde nun vollständig eingeführt und die Ergebnisse bei Anwendung auf die zwölf Realfahrzyklen aus Abbildung 2.7 aufgezeigt. Nun wird die entwickelte Online-ECMS auf Messdaten aus Realfahrten eines Testfahrzeugs angewandt.

5.2 Anwendung der Online-ECMS auf Messdaten aus Realfahrten eines Testfahrzeugs

Zur Anwendung der entwickelten Online-ECMS auf Messdaten aus Realfahrten eines Testfahrzeugs wird zunächst der verwendete *Datensatz zur Validierung* vorgestellt (Kapitel 5.2.1) und das Modell anschließend auf das Testfahrzeug parametriert (Kapitel 5.2.2). Danach werden die Realmessfahrten des Testfahrzeugs verwendet, um in der Simulation die entwickelte Online-ECMS zu erproben. Dadurch erfolgt eine Validierung der entwickelten Online-ECMS, wobei auch Handlungsempfehlungen hinsichtlich der EMS des Testfahrzeugs abgeleitet werden (Kapitel 5.2.3).

5.2.1 Verfügbarer Datensatz und Verifizierung

Um die generische Einsetzbarkeit der entwickelten Online-ECMS zu unterstreichen, werden für die Validierung Messungen eines Testfahrzeugs des F-Segments mit 48 V-Hybridisierung in P1-Topologie herangezogen (Fahrzeugsegmente siehe Tabelle 2.1). Einen Überblick über diesen bereits in Kapitel 2.3.2 erwähnten *Datensatz zur Validierung* gibt Abbildung 5.9. Dabei ist die Gesamtstrecke und die Gesamtdauer für alle Fahrzyklen aufgezeigt. Die *Rohdaten* der Validierungsdaten sind zunächst jeweils als weiße Balken dargestellt. In einem weiteren Schritt werden unvollständige Fahrzyklen bei der ersten/letzten Standphase abgeschnitten. Fahrzyklen unter 15 min Dauer oder 10 km Gesamtdistanz werden für weitere Untersuchungen nicht weiter betrachtet. Diese sind mit grauen Balken als *Cut (Keine Auswahl)* markiert. Mit den Fahrzyklen *Cut (Auswahl)* verbleibt ein Datensatz mit folgenden Eckdaten für die Validierung:

- 34 Messfahrten bzw. Fahrzyklen
- 47 h Gesamtdauer
- 2245 km Gesamtdistanz




Abbildung 5.9: Überblick über die 40 Fahrzyklen aus dem Datensatz zur Validierung der Online-ECMS.

Eine Übersicht über alle verfügbaren Messsignale zur Validierung ist in Anhang G zu finden. Exemplarisch sind an dieser Stelle einige Eckdaten visualisiert (Abbildung 5.10). Dabei ist die mittlere Fahrzeugbeschleunigung a_{avg} , die Fahrbahnsteigung, die maximale Fahrzeuggeschwindigkeit (v_{max}) und der Kraftstoffbedarf in l/100km für die 34 Fahrzyklen aus der Messung aufgetragen. Es zeigt sich, dass das Spektrum von langsamen, dynamischen bis zu schnellen, weniger dynamischen Fahrzyklen abgedeckt ist. Die maximalen Fahrzeuggeschwindigkeiten bewegen sich von 50 km/h im Stadtverkehr bis zu 170 km/h bei Autobahnfahrten. Ebenso zeigt sich bei Betrachtung der 1 % bzw. 3 % Perzentile, dass sich die gemessenen Fahrbahnsteigungen in den Messfahrten überwiegend im Wertebereich -5 % bis + 5 % bewegen. Die gemessenen Kraftstoffverbräuche liegen zwischen 6 l/100 km und 15 l/100 km.

Nachdem der verwendete *Datensatz zur Validierung* nun vorgestellt wurde, wird das Modell im Folgekapitel auf das Testfahrzeug parametrisiert.

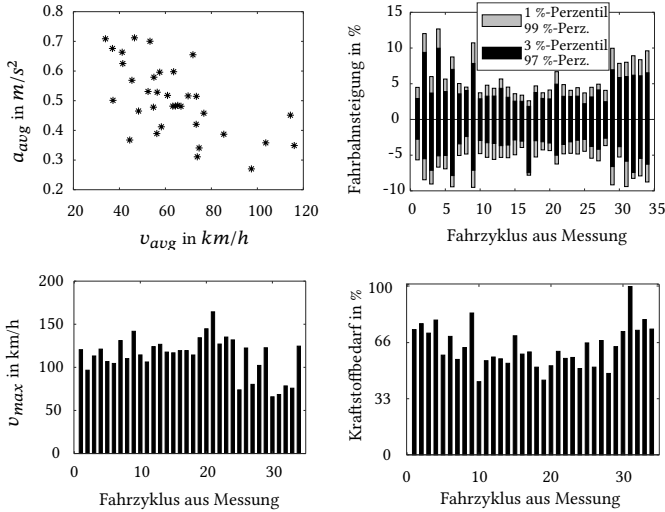


Abbildung 5.10: Kenndaten der 34 ausgewählten Fahrzyklen aus dem *Datensatz zur Validierung* der Online-ECMS. Die Achsen sind teilweise normiert dargestellt. Der Wert 100 % entspricht dem maximalen Kraftstoffbedarf in der Darstellung.

5.2.2 Parametrieren des Modells auf das Testfahrzeug

Wie in Kapitel 2.3.1 erwähnt, wird das Modell von [För24] verwendet, welches im Rahmen seiner Arbeiten bereits validiert wurde. Da die im Simulationsmodell verwendete Parametrierung jedoch auf technischen Daten der Einzelkomponenten und des Gesamtfahrzeugs basiert und diese Parameter nur mit einer gewissen Genauigkeit die realen Parameter des Testfahrzeugs widerspiegeln, wird eine Anpassung durchgeführt. Dadurch wird eine möglichst hohe Übereinstimmung zwischen berechneter und gemessener Leistungs- und Energiebilanz des Testfahrzeugs aus dem F-Segment erzielt, um so eine Validierung der entwickelten Online-ECMS zu ermöglichen. Zur Anpassung werden die Parameter beginnend vom Rad über den Antrieb bis zum Energiespeicher überprüft und Korrekturfaktoren genutzt, um die diese Parameter in einem plausiblen und realistischem Maße zu korrigieren. Entsprechend den bereits in Kapitel 2.3.1 vorgestellten Formeln zur Beschreibung der Längsdynamik eines Kraftfahrzeugs werden im Folgenden

zunächst die Masse m , das für den Luftwiderstand relevante Produkt aus Beiwert c_w und Querschnittsfläche A sowie der Rollwiderstandsbeiwert f_r an die Messdaten angepasst. Die Schwankungen resultieren aus fehlenden Daten zur verwendeten Rad-Reifen-Kombination, den unbekannten alterungs- und nutzungsabhängigen Parametern wie Zuladung, Fülldruck, Verschleiß, Temperatur sowie fehlenden Angaben zu den befahrenen Fahrbahnbelägen (Rauigkeit, Nässe, ...). Hiermit geht auch eine Abweichung im dynamischen Radhalbmesser r_{dyn} einher, welcher im Rahmen der Untersuchungen als konstant angenommen wird (Kapitel 2.3.1).

Längsdynamik (Dynamischer Radhalbmesser r_{dyn})

Durch den bekannten Zusammenhang zwischen translatorischer Fahrzeuggeschwindigkeit des Fahrzeugs, Winkelgeschwindigkeit und Radius lässt sich ein effektiver dynamischer Radhalbmesser $r_{dyn,eff}$ bestimmen, der den Zusammenhang zwischen gemessener Raddrehzahl und Fahrzeuggeschwindigkeit ohne Schlupf repräsentiert. Ein Histogramm über alle Testdaten zeigt, dass dieser mit 0.355 m höher liegt als der im Simulationsmodell ursprünglich auf Grundlage technischer Daten angenommene theoretische, dynamische Radhalbmesser $r_{dyn,theo}$ (Abbildung 5.11). Ein Reifen dreht im Traktionsfall um wenige Prozent schneller als sich geometrisch zur entsprechenden translatorischen Fahrzeuggeschwindigkeit ergeben würde. Dieser Schlupf wird im Modell nicht berücksichtigt. Obgleich durch den Schlupf (der Traktionsfall, also $s > 0$ überwiegt typischerweise) bei Betrachtung von Raddrehzahl und Fahrzeuggeschwindigkeit $r_{dyn,eff} < r_{dyn,theo}$ zu erwarten wäre, wird dieser Effekt durch einen im Zuge der Messfahrten verwendeten, größeren Reifen überkompensiert. Der im Modell hinterlegte r_{dyn} wird entsprechend angepasst. Variierende Antriebskräfte und verbundene Schlupfänderungen führen jedoch stets zu Schwankungen im effektiven, dynamische Radhalbmesser während des Fahrbetriebs. Diese Schwankungen werden weiterhin nicht berücksichtigt.




Abbildung 5.11: Effektiver, dynamischer Radhalbmesser $r_{dyn,eff}$ im Vergleich zu $r_{dyn,theo} = 0.342$ m aus Datenblatt für untersuchtes F-Segment Fahrzeug (vertikale Linie). Messpunkte aus Datensatz zur Validierung (Abbildung 5.10).

Längsdynamik (Fahrwiderstände)

Für eine bestmögliche Parametrierung der übrigen Fahrwiderstandsbeiwerte wird eine Methodik entwickelt, bei der die Messungen in drei Kategorien aufgeteilt werden. Dabei werden für die individuelle Parametrierung stets nur solche Segmente herangezogen, in denen der Einfluss durch den jeweiligen Fahrwiderstandsbeiwert überwiegt: Zur Unterscheidung von Konstantfahrt, Beschleunigungsfahrt und Bremsmanöver wird die Grenzbeschleunigung von $a = 0.139 \text{ m/s}^2$ aus der Entwicklung des World-wide harmonized Light Duty Test Cycle (WLTC) verwendet [Tut15].

Kategorie 1: Beschleunigungswiderstandsrelevante Betriebsphasen

Diese Kategorie umfasst Fahrzeugbeschleunigungsphasen, in welchen sich die Fahrzeugmasse typischerweise besonders stark auswirkt. Dieser Kategorie werden sämtliche Phasen des Fahrzyklus zugeordnet, welche nachfolgendes Kriterium erfüllen (Formel 5.7):

$$a > 0.139 \text{ m/s}^2 \quad (5.7)$$

Kategorie 2: Rollwiderstandsrelevante Betriebsphasen

Diese Kategorie umfasst Konstantfahrten bei geringer Fahrzeuggeschwindigkeit, in welchen sich der Rollwiderstand f_r besonders stark auswirkt. Der Rollwiderstand hat üblicherweise bis zu einem Fahrzeuggeschwindigkeitsbereich von 50-70 km/h den Haupteinfluss auf den Fahrwiderstand und die damit verbundene Antriebsleistung. Auch das Testfahrzeug weist ein entsprechendes Verhalten auf (siehe Abbildung 5.12).




Abbildung 5.12: Rollwiderstand und Luftwiderstand für das Testfahrzeug bis 100 km/h. Ab ca. 70 km/h fällt der Luftwiderstand höher aus als der Rollwiderstand.

Der relevante Geschwindigkeits- und Beschleunigungsbereich wird entsprechend wie folgt festgelegt (Formel 5.8):

$$|a| < 0.139 \text{ m/s}^2 \wedge v < 70 \text{ km/h} \wedge v > 3 \text{ km/h} \quad (5.8)$$

Kategorie 3: Luftwiderstandsrelevante Betriebsphasen

Diese Kategorie umfasst Konstantfahrten bei hoher Fahrzeuggeschwindigkeit, in welchen sich der Luftwiderstand $c_W \cdot A$ besonders stark auswirkt. Der Luftwiderstand hat üblicherweise ab einem Fahrzeuggeschwindigkeitsbereich von 50-70 km/h den Haupteinfluss auf den Fahrwiderstand. Dieser Kategorie werden sämtliche Phasen des Fahrzyklus zugeordnet, welche folgendes Kriterium erfüllen (Formel 5.9):

$$|a| < 0.139 \text{ m/s}^2 \wedge v > 70 \text{ km/h} \quad (5.9)$$

Zur Ermittlung der passenden Parameter werden Parameterstudien für Luftwiderstandsbeiwert, Rollwiderstandsbeiwert und Masse hinsichtlich nachfolgender Gütekriterien für eine bestmögliche Übereinstimmung zwischen Messung und Modell durchgeführt. Die Parametrierung erfolgt dabei ausschließlich mit Messsegmenten aus der jeweils relevanten Kategorie.

- Wurzel des mittleren quadratischen Fehlers (engl. *Root Mean Squared Error*, kurz RMSE) der Kurbelwellenleistung P_{CS}
- Absoluter Fehler der mechanischen Energie an der Kurbelwelle E_{CS}
- Absoluter Fehler der mittleren auftretenden Kurbelwellenleistung P_{CS} (Median / Mittelwert)

Obgleich das anliegende Kurbelwellendrehmoment entscheidend für die EMS ist, wird durch die Leistungsbetrachtung ein Einfluss durch fehlerhafte Übersetzungen resultierend aus einer abweichenden Gangwahl im Realfahrzeug vermieden. Fehler durch die gangspezifischen Wirkungsgrade können nicht ausgeschlossen werden. Aufgrund der in weiten Teilen ähnlichen Verluste (vgl. Abbildung 2.3) kann dieser Einfluss jedoch vernachlässigt werden. Die Ergebnisse der Parameterstudien für alle drei Fahrwiderstandsbeiwerte sind in Abbildung G.1 beispielhaft für den RMSE der Kurbelwellenleistung P_{CS} zwischen Messung und Modell zu sehen. Entsprechend den Analysen geben die Luftwiderstandsbeiwerte aus den Datenblättern den Luftwiderstand im Mittel gut wieder, für den Rollwiderstand lässt sich durch variierende Fahrbahnbeläge kein pauschaler Korrekturfaktor bestimmen. Es erfolgt keine Anpassung des Rollwiderstands. Die Masse hingegen muss korrigiert werden. Deren Parametrierung ist nachfolgend für die vier genannten Gütekriterien dargestellt (Abbildung 5.13). Die grauen Linien stellen die ermittelten Fehler zwischen Messung und Modell für jeden der 34 Fahrzyklen dar. In schwarz ist das arithmetische Mittel über alle Kurven eingezeichnet. Unabhängig vom gewählten Gütekriterium zeigt sich, dass durch eine Korrektur des Leergewichtes um den Faktor 1.2 die beste Übereinstimmung zwischen Mess- und Simulationsergebnis erzielt wird. Diese Massenerhöhung ist durch die im Versuchsfahrzeug vorliegende Tankfüllung, Sonderausstattung und Messtechnik begründbar.




Abbildung 5.13: Parameterstudie zum Korrekturfaktor Masse für das Gütekriterium RMSE Leistung P_{CS} , Abweichung mech. Energie E_{CS} und die mittlere Abweichung von P_{CS} . Fahrzyklen aus Datensatz zur Validierung entsprechend Abbildung 5.10.

Getriebe (Übersetzungen)

Analog zu den Untersuchungen zur Überprüfung des effektiv wirkenden Reifendurchmessers, werden auch die gemessenen *Rad- und Motordrehzahlen* mit den hinterlegten Übersetzungen aus Getriebe und Differential verglichen. Wie in Abbildung 5.14 deutlich zu sehen, decken sich die hinterlegten Übersetzungen des Getriebes (waagerechte Linien) mit den Übersetzungen aus den gemessenen Drehzahlen. Durch Kuppelvorgänge treten jedoch auch Übersetzungen auf, welche sich nicht direkt aus dem verbauten Getriebe und Differential ergeben. Kuppelvorgänge werden im Modell durch entsprechende

Interpolationen nur annähernd dargestellt. Entsprechend ergeben sich während der Gangwechselphasen Unterschiede zwischen dem gemessenen und simulierten Drehzahlverlauf.




Abbildung 5.14: Effektiv auftretende Übersetzungen aus Messungen, aufsteigend sortiert. Übersetzungen aus Getriebe und Differentialgetriebe für die Gänge 1-6 waagrecht eingezeichnet. Messungen aus *Datensatz zur Validierung*, vgl. Abbildung 5.10.

Getriebe (Schaltstrategie)

In Kapitel 2.3.1 wurde gezeigt, dass die Schaltstrategie im Fahrzeug durch eine Hoch- bzw. Herunterschaltgeschwindigkeit definiert ist, welche von der Fahrpedalstellung APP und dem eingelegten Gang abhängt. Dabei gibt die Hochschaltgeschwindigkeit die Geschwindigkeit an, bei der im Falle einer Beschleunigungsfahrt vom niedrigeren auf den höheren Gang geschaltet wird (nicht zu verwechseln mit der Dauer des Schaltvorgangs). Es zeigt sich, dass im Testfahrzeug ein späteres Hochschalten auftritt, als bei den im Modell hinterlegten Standardkennfeldern. Dies ist in Abbildung 5.15 exemplarisch für eine Sequenz dargestellt. Hintergrund hierfür ist eine für Fahrzeuge diesen Typs übliche *Schwerlastapplikation*, um auch bei großer Masse eine entsprechende Agilität zu erreichen. Dies erfolgt durch die bevorzugte Wahl eines niedrigeren Ganges mit höherer Übersetzung, womit eine höhere Drehmomentreserve verbunden ist.

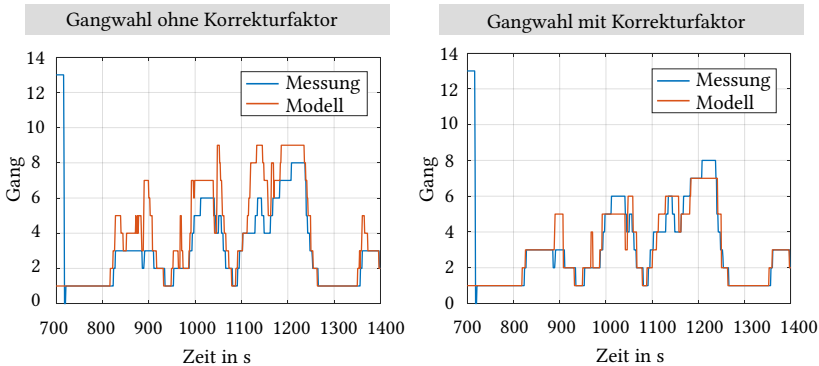


Abbildung 5.15: Einfluss einer erhöhten Hochschaltgeschwindigkeit an einem exemplarischen Segment eines Fahrzyklus aus dem *Datensatz zur Validierung* (Abbildung 5.10). Es ist deutlich zu erkennen, dass mit der im Modell hinterlegten Schaltstrategie (links) ein früheres Hochschalten erfolgt (orangene Kurve). In der Messung hingegen (blaue Kurve) erfolgt erst ein späteres Hochschalten. Teilweise werden die höheren Gänge gar nicht eingelegt ($t = 820$ s bis $t = 930$ s). Durch eine Erhöhung der Hochschaltgeschwindigkeit kann die Übereinstimmung deutlich verbessert werden (rechts).

Es wird ein entsprechender Korrekturfaktor eingeführt, welcher ein verzögertes Hochschalten bewirkt. Der Einfluss auf das bereits in Abbildung 2.3 vorgestellte Schaltkennfeld ist in Abbildung G.2 (Anhang G) dargestellt. Die Parameterstudien werden analog zur Parametrierung der Fahrwiderstandsbeiwerte durchgeführt. Als Gütekriterium dient der RMSE des Gangs zwischen Messung und Modell. Es sei abschließend erwähnt, dass mit dem verspäteten Hochschalten tendenziell auch ein Betrieb bei geringen Wirkungsgraden der VKM verbunden ist. Unabhängig der EMS ist dabei ein signifikanter Einfluss auf den Kraftstoffbedarf festzustellen, was für spätere Absolutbetrachtungen zu berücksichtigen ist.

Verbrennungskraftmaschine und Elektrische Maschine

Zur Verifizierung der Messdaten werden die Kennfelder von VKM und EM exemplarisch nachgerechnet. Das aus den Messdaten errechnete Kennfeld der VKM ist in Abbildung 5.16 dargestellt. Rein visuell zeigt sich eine hohe Übereinstimmung mit dem hinterlegten Kennfeld der VKM (Abbildung 2.4).

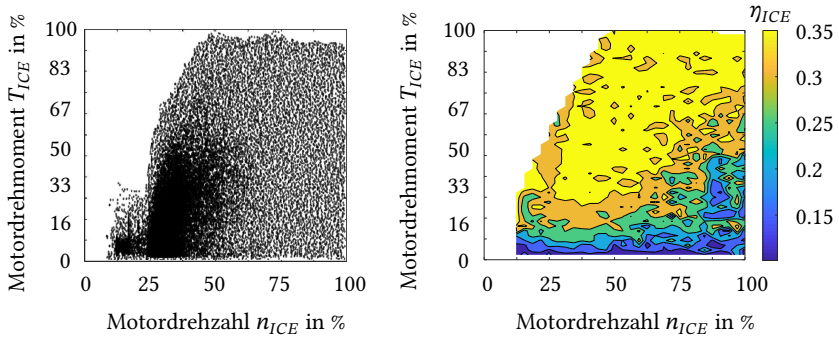


Abbildung 5.16: Berechnung des Kennfeldes der VKM aus dem Datensatz zur Validierung (Abbildung 5.10). Links sind die Messpunkte dargestellt, rechts die errechneten Wirkungsgrade. Das in der Simulation hinterlegte Kennfeld wurde bereits in Abbildung 2.4 eingeführt. Die Achsen sind teilweise normiert dargestellt. Der Wert 100 % entspricht dem maximalen Motordrehmoment in der Darstellung. Ebenso entspricht 100 % jeweils der maximal dargestellten Motordrehzahl.

Zusätzlich wird für die 34 Messfahrten der gemessene Kraftstoffbedarf mit dem sich für die gemessenen VKM-Betriebspunkte ergebenden Kraftstoffbedarf aus den hinterlegten Kennfeldern im Modell abgeglichen. Die gemessenen Betriebspunkte der VKM werden dabei im Kennfeld der VKM simuliert. Es zeigt sich, dass die gemessenen Kraftstoffverbräuche für die gleichen VKM-Betriebspunkte 3-15 % höher ausfallen. Die fahrzyklusspezifischen Abweichungen sind in Abbildung G.3 zu finden. Für Absolutbetrachtungen hinsichtlich zusätzlicher CO_2 -Einsparpotentiale werden daher für eine bessere Vergleichbarkeit des Betriebsverhaltens aus Simulation und realem Fahrbetrieb stets die Verbräuche aus dem VKM-Kennfeld des Simulationsmodells (Abbildung 2.4) herangezogen. Die gemessenen Kraftstoffverbräuche der VKM werden im Folgenden nicht weiter betrachtet. Die Untersuchung der EM-Kennfelder erfolgt analog.

Batterie und Leistungselektronik

Wie bereits im Kapitel 2.3.1 erwähnt, wird ein einfaches Ersatzschaltbild (ESB), bestehend aus Leerlaufspannung U_{OCV} , innerem Widerstand R_i und Klemmenspannung U_{bat} , verwendet (Abbildung 2.6). Es werden die wichtigsten Batterieparameter überprüft, um eine Vergleichbarkeit der Simulations- und

Messergebnisse sicherzustellen. Zunächst werden die vom Batteriemanagementsystem (BMS) geschätzten Batterieladezustände SOC mit den errechneten Batterieladezuständen SOC aus dem gemessenen Batteriestrom I_{bat} verglichen. Dazu werden die sich entsprechend Formel 2.8 ergebenden Werte für $dSOC$ integriert. Zusätzlich muss der Initialladezustand aus der Messung $SOC_{init,measurement}$ hinzuaddiert werden. Damit wird sichergestellt, dass die zum Testfahrzeug passende Batteriekapazität C hinterlegt ist. Während bis hierhin lediglich die SOC-Grenzen einer sehr großen Batterie entsprechend des nutzbaren Energieinhalts gewählt wurden, wird die im Simulationsmodell festgelegte Batteriekapazität an dieser Stelle - für einen Vergleich der absoluten SOC-Werte zwischen Simulation und Testfahrzeug - auf den tatsächlichen Wert angepasst. Es gilt entsprechend Formel 5.10:

$$SOC = \int dSOC + SOC_{init,measurement} \quad (5.10)$$

In einem zweiten Schritt wird entsprechend Formel 2.9 und Formel 2.10 mit den gemessenen Batterieströmen- und spannungen die bereits eingeführte Energieabweichung ΔE_{CS} zum Initialzustand bestimmt. Diese ergibt sich, wie bereits in Kapitel 5.1.2 aufgezeigt, durch die Integration der Energieänderung dE_{bat} (Formel 5.4). Bei Übereinstimmung des Verlaufs von Batterieladezustand und integrierter Energieänderung kann davon ausgegangen werden, dass das verwendete, einfache ESB mit den getroffenen Vereinfachungen (konstante Eigenschaften bei $SOC = 70\%$) das Batterieverhalten ausreichend abbildet und der innere Widerstand R_i richtig gewählt ist. Die Verläufe sind in Abbildung 5.17 für einen exemplarischen Fahrzyklus dargestellt. Der errechnete SOC weist eine gute Übereinstimmung mit dem gemessenen SOC auf. Auch die mit dem einfachen ESB errechnete Energieabweichung ΔE_{CS} passt qualitativ zum SOC-Verlauf.




Abbildung 5.17: Vergleich gemessene Batterieladezustände mit den Batterieladezuständen, die sich durch Integration des gemessenen Batteriestroms ergeben (links). Resultierende Energieabweichung ΔE_{CS} in der Batterie, basierend auf dem einfachen Ersatzschaltbild (rechts). Dargestellt für einen exemplarischen Fahrzyklus des Datensatz zur Validierung aus Abbildung 5.10.

Analysen über alle 34 Fahrzyklen zeigen jedoch, dass es teilweise signifikante Abweichungen zwischen dem aus dem integrierten Strom errechneten SOC und dem gemessenen SOC gibt. Damit ist auch die Aussagekraft der errechneten Energieabweichungen ΔE_{CS} aus dem einfachen ESB begrenzt. Neben möglichen Messfehlern resultieren die Abweichungen aus der kontinuierlichen Neuschätzung des SOC durch das BMS, welche im Simulationsmodell nicht hinterlegt ist. Für den Abgleich mit den Simulationsergebnissen werden fortan ausschließlich die gemessenen Batterieladezustände herangezogen.

Darüber hinaus sind in Abbildung 5.18 die vom BMS geschätzten Batterieladezustände zu Beginn und am Ende der Fahrzyklen dargestellt. Die Werte schwanken insgesamt zwischen 53 % und 90 %, wobei Start- und Endladezustand nur selten übereinstimmen. Beim Testfahrzeug ist der ladungserhaltende Betrieb also nur eingeschränkt gegeben. Durch die Annahme des mittleren Arbeitspunkts der 48 V-Batterie bei 70 % SOC lässt sich im Modell aus dE_{bat} und $dSOC$ (Formel 2.8 und 2.10) ein konstanter Umrechnungsfaktor für die Energiemenge pro 1 % SOC ermitteln. Dabei werden zwar über den gesamten Zyklus konstante Batterieeigenschaften angenommen, allerdings lässt sich

damit aus den gemessenen SOC-Werten direkt auf die gespeicherte Energiemenge schließen (Formel 5.11):

$$\frac{dE_{bat}}{dSOC} \quad (5.11)$$

Für die Batterie des Testfahrzeugs ergibt sich ein Wert von $9.25 \text{ Wh}/1\% \text{ SOC}$. Damit können die Energieabweichungen ΔE_{CS} aus den gemessenen Batterieladezuständen bestimmt werden. Im Gegensatz zu den Energieabweichungen aus Abbildung 5.17, welche mittels ESB berechnet wurden, basieren diese auf den gemessenen Batterieladezuständen SOC unter Anwendung des Umrechnungsfaktors (Formel 5.11) und sind im rechten Teil von Abbildung 5.18 dargestellt.




Abbildung 5.18: Finaler Batterieladezustand über dem initialen Ladezustand der Batterie (links) aus Messungen. Endenergieabweichungen unter Annahme einer konstanten Umrechnung von $9.25 \text{ Wh}/1\% \text{ SOC}$ (rechts). Dargestellt für den Datensatz zur Validierung aus Abbildung 5.10.

Die Ergebnisse zeigen, dass die Endenergieabweichungen ΔE_{CS} maximal einen Betrag von 160 Wh zum Initialzustand im jeweiligen Fahrzyklus erreichen.

Das zur Auslegung der Online-ECMS gewählte Kriterium einer maximalen Endenergieabweichung $\Delta E_{CS,end}$ von ± 100 Wh (Kapitel 5.1.1) übertrifft damit grundsätzlich die im Testfahrzeug eingesetzte EMS hinsichtlich eines ladungserhaltenden Betriebs. Im weiteren Verlauf zeigt sich jedoch, dass eine Anwendung der entsprechend ausgelegten Online-ECMS auf Realfahrzyklen des Testfahrzeugs auch zu höheren Abweichungen führen kann, wenn diese Realfahrzyklen nicht im Rahmen der Auslegung herangezogen wurden (vgl. Abbildung 5.20). Ebenso sei an dieser Stelle betont, dass der Vergleich zwischen Messungen des Testfahrzeugs und den Simulationsergebnissen eine ausreichend genaue Schätzung des SOC durch das BMS, sowie einen passenden Umrechnungsfaktor für $\frac{dE_{bat}}{dSOC}$ voraussetzt.

Nebenverbraucher

Wie von [För21] nachgewiesen, ist es ausreichend, den Verbrauch der Nebenaggregate (inklusive der Klimaanlage) als Konstante zu berücksichtigen. Um einen passenden Wert für die Nebenverbraucherleistung P_{aux} des Testfahrzeugs festzulegen, werden die Nebenverbraucher (NV) für alle vier Quadranten, die sich aus dem Laden und Entladen der Batterie sowie dem motorischen und generatorischen Betrieb der EM ergeben, separat bestimmt. Die vier Quadranten lauten:

- Entladung BAT, Motorischer Betrieb EM ($P_{bat_{dis}} / P_{EM_{mot}}$)
- Entladung BAT, Generatorischer Betrieb EM ($P_{bat_{dis}} / P_{EM_{gen}}$)
- Ladung BAT, Generatorischer Betrieb EM ($P_{bat_{chg}} / P_{EM_{gen}}$)
- Ladung BAT, Motorischer Betrieb EM ($P_{bat_{chg}} / P_{EM_{mot}}$)

Ein Laden der Batterie bei gleichzeitig motorischem Betrieb der EM ist nicht möglich, da im Auto keine zusätzliche elektrische Energiequelle verbaut ist. Basis für die Leistungsberechnung sind die gemessenen Spannungen und Ströme für Batterie und Elektromotor. Es werden in Abbildung 5.19 für jeden Quadranten die vorliegenden Leistungen mittels der Perzentilbetrachtung separat aufgetragen.

Dabei geben die Antennen 1-99 % aller Werte wieder, 5-95 % der Werte entspricht dem blauem Bereich. Zusätzlich ist jeweils die mittlere NV-Leistung $P_{aux,avg}$ sowie der Median der errechneten NV-Leistungen angegeben.

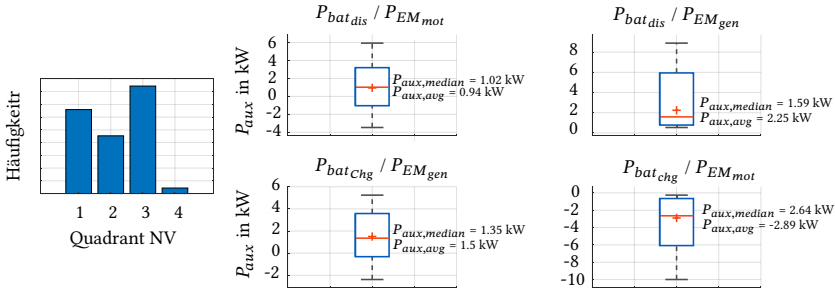


Abbildung 5.19: Leistung Nebenverbraucher für alle vier Quadranten, die sich aus Laden/ Entladen der Batterie sowie motorischem und generatorischem Betrieb der EM ergeben. Häufigkeiten (links), Boxplots (rechts). Basierend auf dem Datensatz zur Validierung aus Abbildung 5.10.

Wie im Histogramm zu erkennen, tritt Fall 3) - Laden der Batterie und generatorischer Betrieb der EM - am Häufigsten auf. Am Zweithäufigsten tritt Fall 1) auf, hier wird die Batterie entladen und der EM wird motorisch betrieben. Das Histogramm zeigt weiterhin, dass auch der Fall eintreten kann, dass der Elektromotor generatorisch arbeitet und gleichzeitig die Batterie entlädt (Fall 2). Hintergrund ist, dass der EM üblicherweise nie im Leerlauf, sondern stets mit kleiner Negativlast generatorisch betrieben wird, um Störgeräusche zu vermeiden. Diese Energie genügt allerdings nicht, um den Energiebedarf der Nebenverbraucher zu decken. Der Abbildung ist außerdem zu entnehmen, dass mit Fall 4) zu einem geringen Anteil eine Ladung der Batterie bei gleichzeitigem motorischem Betrieb der EM auftritt. Auch für Fall 1) und Fall 3) sind vereinzelt negative Leistungen festzustellen. Solche negativen Leistungen für die Nebenverbraucher sind Messfehler. Eine gewichtete Mittelung der Leistungen der vier Quadranten

entsprechend der Verteilung aus dem Histogramm ergibt eine mittlere Nebenverbraucherleistung von ca. 1.3 kW. Zur Plausibilisierung der Daten werden die fahrzyklusspezifisch ermittelten Nebenverbraucherleistungen über den durchschnittlich gemessenen Lufttemperaturen aufgetragen. Die Ergebnisse sind in Anhang G.4 dargestellt. Die erwartete Abhängigkeit der Nebenverbraucherleistung von der gemessenen Lufttemperaturen ist deutlich sichtbar.

Fazit

Insgesamt zeigt sich, dass ein direkter Vergleich der absoluten Größen zwischen Simulation und Messung nur eingeschränkt möglich ist. Entscheidend hierfür sind neben Vereinfachungen im Modell (Kapitel 2.3.1) die Abhängigkeit der vorliegenden Messdaten von teilweise quantifizierbaren, aber auch von nicht direkt quantifizierbaren Betriebsbedingungen in den jeweiligen Messfahrten. Aus diesem Grund wurden die durch Beladung, Außentemperatur und Reifenverschleiß beeinflussten Simulationsparameter fahrzyklusabhängig durch Anpassung der Korrekturfaktoren

- Korrekturfaktor r_{dyn} ,
- Korrekturfaktor Masse,
- Korrekturfaktor Hochschaltgeschwindigkeit und
- Korrekturfaktor Bordnetzlast

zur Erzielung eines möglichst geringen Fehlers zwischen Mess- und Simulationsergebnis angepasst.

Nachdem das Modell nun auf das Testfahrzeug parametrisiert wurde, wird die entwickelte Online-ECMS im nächsten Abschnitt validiert. Dabei werden CO₂-Minderungspotentiale im Vergleich zur EMS des Testfahrzeugs aufgezeigt. Ziel ist die Ableitung von Handlungsempfehlungen zur Optimierung der EMS des Testfahrzeugs.

5.2.3 Validierung der Online-ECMS und Identifikation von Handlungsempfehlungen

Nachfolgend wird die Simulationsumgebung genutzt, um das Zusammenspiel zwischen der Online-ECMS und dem parametrisierten Modell zur Abbildung des Testfahrzeugs für die 34 Messfahrten aus Abbildung 5.9 zu untersuchen. Hierzu werden die Ergebnisse der Online-ECMS mit der theoretischen, kraftstoffoptimalen Lösung aber auch mit der EMS des Testfahrzeugs verglichen. Dabei werden auch Handlungsempfehlungen zur Verbesserung der aktuell im Testfahrzeug angewendeten EMS abgeleitet. Dies umfasst folgende Schritte:

- Auslegung der **Online-ECMS** für das Testfahrzeug
- Analyse der **Online-ECMS** hinsichtlich ladungserhaltendem Betrieb
- Vergleich der **Online-ECMS** mit der **Offline-ECMS**
- Vergleich der **Online-ECMS** mit der gemessenen **EMS des Testfahrzeugs**
- Handlungsempfehlungen für die **EMS des Testfahrzeugs**

Auslegung Online-ECMS für Testfahrzeug

Zunächst muss für das Fahrzeug analog zu den Studien aus Kapitel 5.1 eine Online-ECMS für das Testfahrzeug mittels der zwölf bekannten Standardfahrzyklen aus Abbildung 2.7 parametrisiert werden. Entsprechende Studien führen zu folgenden Einstellungen (Tabelle 5.2).

Tabelle 5.2: Finale Parametrierung Online-ECMS unter Verwendung der zwölf Realfahrzyklen aus Abbildung 2.7 für das Testfahrzeug in P1-Topologie.

$\lambda_{0,avg,P1}$	2.48
$k p_{SOC}$	11

Analyse der Online-ECMS hinsichtlich ladungserhaltendem Betrieb

Im Gegensatz zu Kapitel 5.1.3 wird die Online-ECMS nun auf unbekannte Fahrten angewandt, wodurch die CS-Bedingung hinsichtlich der maximal zulässigen Endenergieabweichung ($-100 \text{ Wh} < \Delta E_{CS, \text{end}} < +100 \text{ Wh}$) nicht zwingend eingehalten wird. Bei den 34 untersuchten Fahrzyklen aus der Messung wird diese Grenze zweimal verletzt (Abbildung 5.20). Im Hinblick auf die in Abbildung 5.18 gezeigten Endenergieabweichungen der EMS des Testfahrzeugs, sind die auftretenden Endenergieabweichungen als vertretbar zu bewerten. Dies zeigt, dass die zwölf Standardfahrzyklen das Spektrum realen Fahrverhaltens gut widerspiegeln und somit für die Auslegung einer Online-ECMS geeignet sind.




Abbildung 5.20: Endenergieabweichung ΔE_{CS} in Wh der Online-ECMS für die 34 Fahrzyklen aus der Messung (*Datensatz zur Validierung*) entsprechend Abbildung 5.10.

Vergleich der Online-ECMS mit der Offline-ECMS

Abbildung 5.21 zeigt, dass der Unterschied der CO_2 -Emissionen der Online-ECMS gegenüber der theoretischen, kraftstoffoptimalen Lösung mit Abweichungen $< 1\%$ über die 34 Fahrzyklen aus der Messung gering ist. Dies deckt sich mit den Ergebnissen bei Anwendung der Online-ECMS auf eine P1-Topologie mit den zwölf Standardfahrzyklen aus Abbildung 5.1. Die vergleichbare Performance hinsichtlich Kraftstoffbedarf resultiert aus dem annähernd gleichen Wert für k_{pSOC} für das Testfahrzeug in P1-Topologie (Tabelle 5.2 im Vergleich zu Tabelle 5.1). Somit wurde bestätigt,

dass die entwickelte Online-ECMS auch auf das hier betrachtete Modell des Testfahrzeugs anwendbar ist. Analog zu Abbildung 5.7 treten auch hier teilweise Verbesserungen gegenüber der optimalen Offlinelösung auf, die aus numerischen Fehlern resultieren. Diese numerischen Fehler liegen mit bis zu 0.3 % - im Vergleich zu den maximalen Verschlechterungen der Online-ECMS gegenüber der Offline-ECMS von bis zu 0.8 % - vergleichsweise hoch. Wie bereits in Kapitel 5.1.3 erwähnt, lässt sich dies damit erklären, dass sich das Betriebsverhalten einer Online-ECMS mit SOC-abhängiger Regelung des Äquivalenzfaktors nahe am Optimum bewegt, was auch in der Literatur bestätigt wird. Gleichzeitig stellt eine Online-ECMS den ladungserhaltenden Betrieb (CS) nur in einem begrenzten Rahmen sicher (Abbildung 5.20), sodass bei den mit der Online-ECMS ermittelten Verbräuchen für eine Vergleichbarkeit mit der Offline-ECMS ein Korrekturterm zur Anwendung kommt (Formel 5.13 und 5.14). Aufgrund der hierbei gemittelten Wirkungsgrade über den Fahrzyklus ist die Korrektur der CO_2 -Emissionen der Online-ECMS mit einer gewissen Unschärfe verbunden.




Abbildung 5.21: Ergebnisse der Online-ECMS im Vergleich zur global optimalen Lösung (Offline-ECMS) für die 34 Fahrzyklen aus der Messung hinsichtlich CO_2 -Emissionen (*Datensatz zur Validierung* entsprechend Abbildung 5.10). Negative Werte bedeuten eine Verschlechterung der Online-ECMS gegenüber der Offline-ECMS.

Vergleich Online-ECMS zur gemessenen EMS des Testfahrzeugs

Mittels der Energieabweichung zum Referenzladezustand ΔE_{CS} entsprechend Formel 5.4 lässt sich auch der tatsächlich genutzte Energieinhalt der Batterie $\Delta E_{CS,min,max}$ bestimmen (Formel 5.12). Dieser ergibt sich als Differenz aus maximaler (ΔE_{min}) und minimaler (ΔE_{min}) Batterieenergie über den Fahrzyklus:

$$\Delta E_{CS,min,max} = \Delta E_{CS,max} - \Delta E_{CS,min} \quad (5.12)$$

Hierfür ist in Abbildung 5.22 der genutzte Energieinhalt der Batterie der Online-ECMS über dem genutzten Energieinhalt der Batterie des Testfahrzeugs über alle 34 Fahrzyklen aus der Messung aufgetragen. Es zeigt sich, dass die genutzten Energieinhalte der vorgestellten Online-ECMS gegenüber der gemessenen EMS des Testfahrzeugs überwiegend geringer ausfallen.




Abbildung 5.22: Vergleich des genutzten Energieinhalts der Batterie $\Delta E_{CS,min,max}$ der Online-ECMS im Vergleich zur EMS des Testfahrzeugs. Fahrzyklen aus Messung entsprechend Abbildung 5.10 (Datensatz zur Validierung).

Wie bereits in Kapitel 5.1.2 erwähnt, kann im Spezialfall einer bekannten Route kp_{SOC} zunächst geringer gewählt werden, um einen höheren Energieinhalt der Batterie zu nutzen und somit eine weitere CO_2 -Reduktion zu erreichen. Zum Ende der Route muss kp_{SOC} jedoch vergrößert werden um CS einzulassen. Dies steht jedoch im Widerspruch zur robusten Einsetzbarkeit.

Nun wird die EMS des Testfahrzeugs mit der Online-ECMS hinsichtlich des zusätzlichen CO₂-Einsparpotentials verglichen. Da die Abweichungen zwischen der entwickelten Online-ECMS und der Offline-ECMS entsprechend Abbildung 5.21 < 1% liegen, werden im Folgenden für eine einfachere Vergleichbarkeit mit der Messung stellvertretend die Ergebnisse der Offline-ECMS herangezogen. Hintergrund hierfür ist, dass die Offline-ECMS im Gegensatz zur Online-ECMS einen ladungserhaltenden Betrieb (CS) sicherstellt. Trotz dieser Vereinfachung sind weitere Korrekturen notwendig, um die errechneten CO₂-Emissionen mit den gemessenen Werten vergleichen zu können.

Korrektur 1: Ladezustände der Batterie

Entsprechend Abbildung 5.18 weicht der Endladezustand in den Messungen teilweise stark vom jeweiligen Initialzustand ab, während die für ein Verständnis der Betriebsweise der Online-ECMS herangezogene Offline-ECMS stets einen CS-Betrieb forciert. Die Basislösung der Simulation muss deshalb um die Endenergieabweichung aus der Messung korrigiert werden. Ist die Batterie in der Messung zum Ende höher geladen, als zu Beginn, werden die CO₂-Emissionen der Simulation entsprechend erhöht. Ist der Ladezustand in der Messung hingegen geringer als zu Beginn, müssen die errechneten CO₂-Emissionen entsprechend verringert werden. Dafür wird zunächst mittels des im vorherigen Kapitel 5.2.2 bestimmten Werts von 9.25 Wh/1% SOC die Endenergieabweichung $\Delta E_{CS,end}$ aus den gemessenen Batterieladezuständen bestimmt. Anschließend werden die CO₂-Emissionen mittels des durchschnittlichen, fahrzyklusspezifischen Gesamtwirkungsgrads $\eta_{corr,ges}$ korrigiert. Die Logik wurde von [För24] übernommen, wird jedoch an dieser Stelle kurz erläutert. Für die Korrektur wird der durchschnittliche Wirkungsgrad der VKM $\eta_{ICE,avg}$, der durchschnittliche Wirkungsgrad der EM $\eta_{EM,avg}$ und der durchschnittliche Wirkungsgrad der Batterie $\eta_{bat,avg}$ über den Fahrzyklus herangezogen. Ist der Endladezustand zu gering ($\Delta E_{CS,end} < 0$), gilt folgende Rechenvorschrift zur Bestimmung des entsprechenden mittleren Wirkungsgrads $\eta_{corr,ges,undercharge}$ (Formel 5.13):

$$\eta_{corr,ges,undercharge} = \eta_{ICE,avg} \cdot \eta_{EM,avg} \cdot \eta_{bat,avg} \quad (5.13)$$

Dabei wird angenommen, dass bei einer zu geringen Ladung die für einen ladungserhaltenden Betrieb fehlende Energie in der Batterie von der VKM hätte aufgebracht werden müssen, um durch generatorischen Betrieb die Batterie unter der Berücksichtigung der Wirkungsgrade zu speisen. Bei einer Überladung der Batterie ($\Delta E_{CS,end} > 0$) wird hingegen davon ausgegangen, dass die in der Batterie gespeicherte elektrische Energie nicht rechtzeitig zum motorischen Vortrieb genutzt wurde. Die elektrische Energie wäre dabei unter Berücksichtigung der Batterie- und Elektromotorwirkungsgrade in mechanische Energie auf die Kurbelwelle gewandelt worden. Dieser überschüssige Energiebetrag wurde durch die VKM aufgebracht, sodass deren CO_2 -Emissionen entsprechend korrigiert werden müssen. Für den mittleren Wirkungsgrad $\eta_{corr,ges,overcharge}$ (Formel 5.14) gilt damit:

$$\eta_{corr,ges,overcharge} = \frac{\eta_{ICE,avg}}{\eta_{bat,avg} \cdot \eta_{EM,avg}} \quad (5.14)$$

Damit müssen die auf die Strecke bezogenen, errechneten CO_2 -Emissionen aus dem Simulationsmodell ($\text{CO}_{2,basic}$) in g/km unter Berücksichtigung von $\Delta E_{CS,end}$ in kJ auf $\text{CO}_{2,corr}$ in g/km korrigiert werden. Entsprechend Formel 5.15 erfolgt dies mittels des unteren Heizwerts H_u in kJ/kg , der Gesamtdistanz d_{total} in km , der Kraftstoffdichte ρ_{fuel} in kg/l und dem Umrechnungsfaktor von 23.2 in $\frac{\text{gCO}_2}{\text{l}}$:

$$\text{CO}_{2,corr} = \text{CO}_{2,basic} - 23.2 \frac{\Delta E_{CS,end}}{\eta_{corr,ges} \cdot H_u \cdot \rho_{fuel} \cdot d_{total}} \quad (5.15)$$

Korrektur 2: Rekuperation

Grundsätzlich können durch eine vermehrte Rekuperation von Bremsenergie zusätzliche Einsparpotentiale erzielt werden. Entsprechend Abbildung G.5 aus Anhang G werden im ECMS-Modell größere Energiemengen rekuperiert als in der Messung des Testfahrzeugs. Auch hier können die berechneten CO_2 -Emissionen aus der Simulation unter Berücksichtigung des durchschnittlichen Wirkungsgrads $\eta_{corr,ges}$ um die zusätzlich rekuperierte Energiemenge

erhöht werden, um eine bessere Vergleichbarkeit mit den gemessenen CO_2 -Emissionen zu ermöglichen.

Die Ergebnisse sind in Abbildung 5.23 dargestellt, wobei sich die angegebenen CO_2 -Emissionen stets wie in Kapitel 5.2.2 beschrieben aus dem Kennfeld der VKM berechnen (Abbildung 2.4). Die gemessene EMS des Testfahrzeugs wird dabei im VKM-Modell simuliert. Die um die Endenergieabweichung in der Messung korrigierten Verbräuche (*ECMS Korrektur 1*) fallen mal größer und mal geringer als die errechneten Basisverbräuche (*Basis*) aus. Dies hängt davon ab, ob der Endladezustand bei der Messung höher oder geringer als der Ladezustand zu Beginn ausfällt. Bei zusätzlicher Korrektur um die rekuperierte Energie (*ECMS Korrektur 2*) ist eine stetige Zunahme gegenüber *ECMS Korrektur 1* festzustellen. Entsprechend den Untersuchungen ergeben sich Einsparpotentiale im Bereich weniger Prozente durch eine vollständige Nutzung der Bremsenergie (*ECMS Korrektur 2* gegenüber *ECMS Korrektur 1*). Insgesamt verbleibt in den betrachteten Fahrzyklen eine Abweichung von $< 5\%$ zur Messung (*ECMS Korrektur 2* gegenüber *Messung*). Daraus kann geschlossen werden, dass die Online-ECMS eine kraftstoffsparendere EMS bestimmt als die im Testfahrzeug implementierte EMS.




Abbildung 5.23: Vergleich der errechneten CO_2 -Werte für ausgewählte Fahrzyklen aus der Messung (*Datensatz zur Validierung*). Nach der Korrektur der Basisverbräuche verbleibt in den betrachteten Fahrzyklen eine Differenz zur Messung (schwarze Balken gegenüber türkisfarbene Balken). Dargestellt für sieben ausgewählte Fahrzyklen aus Abbildung 5.10. Die Achsen sind teilweise normiert abgebildet. Der Wert 100 % entspricht den maximalen CO_2 -Emissionen in der Darstellung.

Aus den bisherigen Analysen lässt sich schließen, dass ein Potential zur Verringerung der CO_2 -Emissionen bei Anwendung der Online-ECMS im Vergleich zur EMS des Testfahrzeugs besteht. Allerdings lassen sich abgesehen von den ungenutzten Rekuperationspotentialen (durch die im Testfahrzeug nur eingeschränkte Nutzung der vorhandenen Bremsenergie) bis hierhin keine Rückschlüsse ziehen, woraus das verbleibende CO_2 -Einsparpotential resultiert, um Handlungsempfehlungen abzuleiten. Es kann also nicht erklärt werden, warum die Online-ECMS bessere Werte liefert. Eine exakte Nachbildung der Rekuperationsstrategie des Testfahrzeugs ist komplex und nicht Schwerpunkt der Arbeit. Stattdessen wird das Rekuperationsverhalten bestmöglich angenähert. Hierbei wird das sich aus den Komponentengrenzen ergebende, maximal rekuperierbare Drehmoment durch einen Korrekturfaktor so begrenzt, dass die rekuperierte Energie über den Fahrzyklus zwischen Modell und Messung gleich ist. Dafür wird neben den in Kapitel 5.2.2 vorgestellten Stellhebeln ein zusätzlicher Korrekturfaktor eingeführt:

- Korrekturfaktor Rekuperation

Mit diesem zusätzlichen Korrekturfaktor wird die Rekuperationsstrategie auf ein weiteres Gütekriterium parametrisiert:

- Absoluter Fehler der rekuperierten Energie

Zusätzlich wird der Äquivalenzfaktor λ fahrzyklusspezifisch so gewählt, dass sich derselbe Endladezustand einstellt wie in der Messung. Eine nachträgliche Korrektur der CO_2 -Emissionen ist nicht mehr notwendig und das Betriebsverhalten von Online-ECMS und EMS im Testfahrzeug können direkt miteinander verglichen werden. Somit ist auch eine Ableitung von weiteren Handlungsempfehlungen möglich.

Nachfolgend sind die resultierenden Betriebspunkte der VKM sowohl für die Online-ECMS als auch die Messung für einen exemplarischen Fahrzyklus gezeigt. Zunächst wird in Abbildung 5.24 ein Histogramm der Motordrehmomente T_{ICE} dargestellt. Zusätzlich sind die Wirkungsgrade η_{ICE} in Abhängigkeit des Drehmomentes T_{ICE} für verschiedene Drehzahlen dargestellt. Es ist zu erkennen, dass im Modell (ECMS) höhere VKM-Drehmomente gefahren werden, als bei den Messungen aus dem Testfahrzeug. Gleichzeitig ist im

Kennfeld im Bereich geringer Motordrehmomente ein Abfall der Wirkungsgrade zu verzeichnen.




Abbildung 5.24: Histogramm der Motordrehmomente T_{ICE} für einen exemplarischen Fahrzyklus. Zusätzlich sind die Wirkungsgrade η_{ICE} in Abhängigkeit des Drehmomentes T_{ICE} aufgetragen. Dargestellt für einen exemplarischen Fahrzyklus aus Abbildung 5.10 (Datensatz zur Validierung).

In Abbildung 5.25 ist ein Histogramm der gefahrenen Wirkungsgrade der VKM η_{ICE} abgebildet. Es ist zu erkennen, dass in der Messung des Testfahrzeugs geringere Wirkungsgrade gefahren werden, als im Modell (ECMS).




Abbildung 5.25: Histogramm der gefahrenen Wirkungsgrade der VKM η_{ICE} . Dargestellt für einen exemplarischen Fahrzyklus aus Abbildung 5.10 (Datensatz zur Validierung).

Um Handlungsempfehlungen abzuleiten, werden die Lastpunktverschiebungen (LPV) im Detail überprüft. Dafür werden für einen exemplarischen Fahrzyklus in Abbildung 5.26 alle Punkte herausgefiltert, bei denen die gemessenen VKM-Betriebspunkte ($T_{ICE,measurement}$) besonders niederlastig und die VKM bei besonders geringen Wirkungsgraden betrieben wird. Für eine Vergleichbarkeit wird außerdem vorausgesetzt, dass die Differenz zwischen Messung und Modell des an der KW bereitgestellten Drehmoments ($T_{CS,model}$ bzw. $T_{CS,measurement}$) im Betrag bei maximal 25 Nm liegt. Es ergeben sich folgende Bedingungen für die ausgewählten Punkte (Formel 5.16):

$$\begin{aligned} 0Nm < T_{ICE,measurement} < 30Nm \wedge \\ |T_{CS,model} - T_{CS,measurement}| < 25Nm \end{aligned} \quad (5.16)$$




Abbildung 5.26: Analyse Lastpunktanhebung (LPAn) Messung gegenüber der ECMS in Simulation: Summendrehmoment an der Kurbelwelle (oben), Drehmoment der EM (mitte) und Drehmoment der VKM (unten) für Betriebspunkte, welche die Bedingung aus Formel 5.16 erfüllen. Dargestellt für einen exemplarischen Fahrzyklus des Datensatzes zur Validierung (vgl. Abbildung 5.10).

Hierbei lassen sich zwei Effekte hervorheben:

- Insbesondere in den *gelb markierten* Bereichen zeigt sich, dass beim untersuchten P1 bei der Online-ECMS bei negativen Drehmomentanforderungen an der Kurbelwelle ($T_{CS} < 0$) ein konsequentes Schleppen der VKM ($T_{ICE} < 0$) eingeleitet wird. Bei der gemessenen EMS des Testfahrzeugs wird stattdessen ein geringes positives Drehmoment ($T_{ICE} > 0$) mit geringem Wirkungsgrad η_{ICE} gestellt, wodurch betragsmäßig größere generatorische Drehmomente am EM gestellt werden, um das gleiche Drehmoment an der Kurbelwelle T_{CS} aufzubauen (vgl. Abbildung 5.24). Eine Überprüfung, inwiefern dies aus Sicht der Abgasnachbehandlung oder für ein direktes Ansprechverhalten des Motors zwingend notwendig ist, ist nicht Schwerpunkt der Arbeit.
- Ebenso zeigt sich über alle in Abbildung 5.26 aufgetragenen Betriebspunkte, dass der EM bei der EMS des Testfahrzeugs öfter bzw. betragsmäßig höher generatorisch betrieben wird, als bei der Online-ECMS. Die rote Linie beim Elektromotordrehmoment T_{EM} liegt also über alle dargestellten Betriebspunkte tendenziell unter der grauen Linie. Hinsichtlich eines möglichst kraftstoffoptimalen Betriebs entsprechend der Online-ECMS scheint jedoch diese damit verbundene, quasi-permanente LPAn nicht kraftstoffoptimal. Die Analysen legen nahe, dass stattdessen eine gezielte und konsequente LPAn bei geringen positiven Kurbelwellenleistungen ($T_{CS} > 0$) in den *rot markierten* Bereichen insgesamt effektiver ist.

Es sei insgesamt darauf hingewiesen, dass quantitative Aussagen an dieser Stelle kritisch betrachtet werden müssen. Zum einen ist die Anwendung von LPAn stark von der Gangübersetzung und der Korrektur der Schaltstrategie abhängig. Werden geringe Lasten gefahren, führt dies zu einem direkten Anstieg der Punkte mit LPAn. Zum anderen haben auch Schwankungen des Drehmoments an der Kurbelwelle T_{CS} direkten Einfluss auf die gefahrenen Betriebspunkte.

Handlungsempfehlungen für die EMS des Testfahrzeugs

Folgende Handlungsempfehlungen für die EMS des Testfahrzeugs ergeben sich aus den Analysen:

- Mehr Rekuperation zulassen. Einsatz der mechanischen Bremsen vermeiden.
- Vermeidung kleine VKM Drehmomente
 - Pos. KW-Anforderung: LPAn in VKM-Kennfeldbereiche hohen Wirkungsgrades. EM entsprechend generatorisch betreiben.
 - Neg. KW-Anforderung: Konsequentes Schleppen der VKM, Restmoment rekuperieren über EM
- Mehr reinen VKM-Betrieb zulassen, LPV reduzieren, sofern applikationstechnisch möglich

Analog zum Zielkonflikt CO₂-Einsparpotential gegenüber Fahrkomfort (repräsentiert durch VKM-Start/Stopps) aus den vorherigen Kapiteln obliegt es auch hier letztlich den Entwicklern zu entscheiden, welche Maßnahmen im Fahrzeug realisierbar sind.

Die entwickelte Online-ECMS wurde in Kapitel 5.1 beschrieben und in Kapitel 5.2 auf Messdaten aus Realfahrten eines Testfahrzeugs angewandt. Der Einsatz der entwickelten Online-ECMS auf Realmessfahrten im Testfahrzeug erfolgte dabei in der Simulation, wobei die Geschwindigkeitstrajektorie der realen Testfahrten übernommen wurde. Die entwickelte Online-ECMS konnte somit validiert werden und außerdem Handlungsempfehlungen zur EMS des Testfahrzeugs abgeleitet werden. Nachfolgend werden eine mögliche Implementierung der vorgestellten Online-ECMS im realen Fahrzeug beschrieben sowie die Echtzeitfähigkeit des Ansatzes nachgewiesen.

5.3 Fahrzeugimplementierung und Echtzeitfähigkeit

Wie bereits im V-Modell in Abbildung 1.1 aufgezeigt, ist die Implementierung nicht Teil dieser Forschungsarbeit. Dennoch wird kurz beschrieben, wie die Implementierung im realen Fahrzeug möglich ist. Grundsätzlich werden die Nachrichten auf dem CAN-Bus (einem seriellen Bussystem, engl. *Controller Area Network*) des Fahrzeugs innerhalb weniger Millisekunden übermittelt. Eine Ausgabe der notwendigen Stellgrößen in dieser Frequenz ist mit der entwickelten Online-ECMS nicht realisierbar. Eine Implementierung im Fahrzeug mit dem vorhandenen Modell basiert daher auf folgenden Gedanken:

- Zunächst werden einige Signale benötigt, die im Bereich weniger Millisekunden vom CAN-Bus bereitgestellt und zur Bestimmung der optimalen Drehmomente von VKM und EM benötigt werden.
 - Fahrzeuggeschwindigkeit
 - Gang
 - Fahrzeugbeschleunigung
 - Übersetzung
 - Drehzahl Rad
 - Drehmoment KW
 - Drehmoment Rad
 - Drehzahl KW
- Nachdem die optimale Drehmomentverteilung von der Online-ECMS mittels des Modells bestimmt wurde, wird das berechnete Verhältnis des / der EM-Drehmoment(e) zum KW-Drehmoment konstant gehalten, bis von der Online-ECMS ein neuer Wert berechnet wird. Die Absolutwerte des/der EM- und des VKM-Drehmoments werden dabei im Millisekunden-Takt abhängig vom KW-Drehmoment mit festgelegtem Verhältnis angepasst.
- Geht man von der Rechenleistung eines gängigen Laptops (Intel Core i7 6600U CPU @ 2.6 GHz) im Fahrzeug aus, ergeben sich folgende Zeiten, bis im Fahrzeug ein neuer Wert für das optimale Drehmomentverhältnis zwischen VKM und dem bzw. den EM bestimmt werden kann (Abbildung 5.27).




Abbildung 5.27: Rechendauern der robusten Online-ECMS zur Berechnung der Drehmomentverteilung. Dargestellt für alle vier untersuchten Topologien P1 (links, oben), P2 (rechts, oben), P14 (links, unten), P24 (rechts, unten) für einen exemplarischen Fahrzyklus aus dem *Datensatz zur Validierung* (Abbildung 5.10).

Es ist zu erkennen, dass die notwendige Berechnung für einen P1-Hybrid am Häufigsten in 10 ms (100 Hz) durchgeführt werden kann. Für einen P14-Hybrid wird hingegen im Mittel eine Dauer von 40 ms (25 Hz) benötigt. Die Rechenzeiten für das ECMS-Modell für die Topologien P1 und P2 bzw. P14 und P24 sind dabei nahezu gleich. Durch eine Erhöhung der verbauten Prozessorleistung im Fahrzeug können die Rechenzeiten weiter gesenkt werden. Einen gleichen Effekt kann die Anwendung neuer Rechenmethoden im Algorithmus erzielen. So sind aus dem Bereich der ADP Methoden bekannt, mit denen beispielsweise durch eine Approximation einzelner Teile des Modells über Polynome n -ten Grades eine deutliche Reduktion der Rechenzeiten möglich ist, z. B. [Joh08]. Hierauf liegt jedoch nicht der Schwerpunkt dieser Arbeit.

Die aufgezeigten Rechenzeiten legen nahe, dass eine Implementierung im Fahrzeug entsprechend der beschriebenen Vorgehensweise grundsätzlich möglich ist. Das vorliegende ECMS-Modell in Kombination mit der genannten Rechenleistung ermöglicht eine Aktualisierung der Drehmomentverteilung je nach Topologie in maximal 100 ms. Die Online-ECMS weist dabei entsprechend den vorangegangenen Untersuchungen einen nahezu kraftstoffoptimalen Betrieb auf und kann auch Aspekte des Fahrkomforts wie beispielsweise ein gewünschtes Maß an VKM-Start/Stopp mitberücksichtigen, wobei grundsätzlich auch eine Erweiterbarkeit auf weitere Anforderungen, wie beispielsweise eine hohe Agilität, besteht. Detaillierte Untersuchungen, mit welcher Rechenzeit die Anforderungen an Energieeffizienz, Agilität und Komfort in welchem Maße erfüllt werden, entfallen im Rahmen der Arbeit.

Nachdem in Kapitel 5.1 die eingeführte Online-ECMS aufgezeigt, diese in Kapitel 5.2 auf Messdaten aus Realfahrten eines Testfahrzeugs angewandt wurde und außerdem eine mögliche Implementierung der vorgestellten Online-ECMS im realen Fahrzeug beschrieben wurde, wird das Forschungsfeld *EMS im realen Fahrbetrieb* durch ein Zwischenfazit abgeschlossen.

5.4 Zwischenfazit EMS im realen Fahrbetrieb

Im Rahmen dieses Kapitels wurde eine nichtprädiktive Online-ECMS entwickelt und deren Anwendbarkeit auf unbekannte Fahrzyklen aus einer Messung nachgewiesen. Dabei gilt es kritisch festzuhalten, dass die zwölf verwendeten Realfahrzyklen zwar die statistischen Merkmale von über 1 000 000 km beinhalten, eine Gleichgewichtung der zwölf Fahrzyklen zur Bestimmung von $\lambda_{0,avg}$ jedoch eine Vereinfachung darstellt. Hier könnte für Folgeuntersuchungen auch eine Gewichtung eingeführt werden. Im Hinblick auf die Validierung scheint diese Vereinfachung vertretbar. Es gilt zudem kritisch festzuhalten, dass die Valierungsfahrten zwar das Spektrum realen Fahrbetriebs, wie in Abbildung 5.10 aufgezeigt, bestmöglich abbilden, die Abbildung der statistischen Merkmale von über 1 000 000 km, wie sie in den zwölf Realfahrzyklen aus Abbildung 2.7 repräsentiert sind, ist jedoch nicht zwingend gegeben. Es zeigt sich außerdem, dass die Betrachtung von Absolutwerten

bei Anwendung der Online-ECMS auf ein Modell des Testfahrzeugs herausfordernd ist. Hier ist eine Vergleichbarkeit erst nach der Einführung einiger Korrekturfaktoren möglich. Dies resultiert zum einen aus den identifizierten Messungenauigkeiten zum anderen aus den Modellgrenzen. Eine höhere Aussagekraft der Absolutwerte wäre denkbar durch:

- komplexere Kennfelder zur exakteren Abbildung von VKM, EM und BAT im Simulationsmodell;
- exakte Nachbildung der Schaltstrategie des Testfahrzeugs im Simulationsmodell;
- exaktere Abbildung der last- und betriebssituationsabhängigen Rekuperationsstrategie im Simulationsmodell;
- verbesserte Messungen durch eine genauere Schätzung des Kraftstoffmassenstroms sowie der Batteriegrößen im Fahrzeug.

Insgesamt zeigt die Validierung [För24] eine ausreichende Genauigkeit der Modellierung von Fahrzeug, Antriebsstrang und den Komponenten des 48V-Systems. Eine detaillierte Betrachtung der Schätzung von Kraftstoffmassenstrom und der Batteriegrößen im Fahrzeug bedarf einer Untersuchung der entsprechenden Steuergeräte, was nicht Schwerpunkt der Arbeit ist. Die EMS des Testfahrzeugs zeigt insgesamt ein ähnliches Verhalten wie die Online-ECMS. Obgleich die Quantifizierung der exakten Einsparpotentiale der Online-ECMS mit letzter Gewissheit erst im Rahmen einer Realimplementierung in einem Testfahrzeug möglich ist, konnten die grundsätzliche Anwendbarkeit der Online-ECMS nachgewiesen und entsprechende Handlungsempfehlungen qualitativ abgeleitet werden.

6 Potentiale prädiktiver Energiemanagementstrategien (48 V-System)

Wie im vorigen Kapitel beschrieben, lassen sich mit der erarbeiteten robusten, nichtprädiktiven Online-ECMS Ergebnisse erzielen, die dem globalen Optimum sehr nahe kommen. Die entwickelte EMS wurde mittels den vorgestellten zwölf Realfahrzyklen aus [För20], welche die Eigenschaften von über 1 000 000 km Realfahrdaten repräsentieren, ausgelegt und im Anschluss mit Dauerläuferdaten validiert. Es bleibt die Frage offen, ob und wenn ja, in welchen Fällen prädiktive Konzepte einen Mehrwert gegenüber der nichtprädiktiven Implementierung aus Kapitel 5 in der Anwendung auf 48 V-Hybride erzielen. Wie bereits in Kapitel 2.3.2 erwähnt, wird hierzu zusätzlich der *Alternative Datensatz* herangezogen, um entsprechende Untersuchungen zu den Potentialen prädiktiver EMS durchzuführen. Der *Alternative Datensatz* wird im Anhang H vorgestellt und wurde entsprechend Anhang I aufbereitet. Sämtliche Inhalte dieses Kapitels inklusive der referierten Anhänge wurden bereits im Rahmen der Veröffentlichungen von Deufel et al. [1-4] vorgestellt und beantwortet unter anderem die Fragen:

- Mit welchen datengetriebenen Methoden lassen sich Prädiktionen mit dem Anspruch an eine möglichst generische und robuste Einsetzbarkeit grundsätzlich realisieren?
- Wie lassen sich für den Fall der vorgestellten, nichtprädiktiven Online-ECMS zusätzliche Einsparpotentiale durch die Berücksichtigung prädizierter Informationen erzielen?

Bisher wurde in der Arbeit davon ausgegangen, dass der Verlauf der Geschwindigkeit über die gesamte Strecke hinweg vorgegeben ist (Kapitel 4) oder für den Betrieb der onlinefähigen EMS nicht benötigt wird (Kapitel 5). Grundsätzlich kann eine onlinefähige EMS durch die Nutzung von prädiktiven Informationen verbessert werden, wobei beispielsweise das zukünftige Geschwindigkeitsprofil vorhergesagt werden kann (vgl. Kapitel 3.4.1). Hierbei kann die Route unbekannt, aber - beispielsweise durch das Navigationssystem - auch vorgegeben sein, wobei mit den in der vorliegenden Arbeit entwickelten Verfahren stets eine robuste Einsetzbarkeit gewährleistet ist. In diesem Zuge wird in Kapitel 6.1 zunächst auf entsprechende Prädiktionsalgorithmen eingegangen. Die Grundlagen der herangezogenen Verfahren wurden bereits im *Stand des Wissens* in Kapitel 3.4.2 eingeführt, wobei nun die im Rahmen der Arbeit entwickelten Methodiken zur Vorhersage der notwendigen, drehmomentrelevanten Größen vorgestellt werden (Kapitel 6.1). Anschließend werden die jeweiligen Prädiktionen diskutiert (Kapitel 6.2) und im Folgekapitel zwei Konzepte für eine prädiktive Online-ECMS vorgestellt, die jeweils eine Weiterentwicklung der im vorherigen Kapitel vorgestellten, nichtprädiktiven Online-ECMS darstellen (Kapitel 6.3). Abschließend wird ein Zwischenfazit gezogen (Kapitel 6.4).

6.1 Prädiktion mittels datengetriebener Verfahren

Wie bereits in Kapitel 3.4 beschrieben, muss im Allgemeinen für den Einsatz prädiktiver EMS das zur Bewältigung der Fahraufgabe benötigte Drehmoment für einen bestimmten Zeithorizont bekannt sein, um hierauf basierend mittels einer Modellprädiktiven Regelung (MPC) eine optimale Steuerung zu bestimmen. Dieses Drehmoment hängt im Wesentlichen von der zukünftigen Fahrzeuggeschwindigkeit, der Fahrzeugbeschleunigung und Fahrbahnsteigung ab. Somit müssen diese Größen über den gewählten Horizont mit geeigneten Verfahren präzisiert werden, um die erwartete Drehmomentanforderung anhand eines Fahrzeugmodells zu berechnen. Damit kann schließlich für jeden Zeitschritt eine optimale Steuerung durch den gewählten Optimierer ermittelt

werden. Im Folgenden werden verschiedene datengetriebene Ansätze simulativ verglichen und auf ihre Eignung zur Realisierung solcher Vorhersagen untersucht. Dabei werden Markov-Ketten (MC) mit Vorwärtsgerichteten Neuronalen Netzwerken (FFNN) verglichen. Ebenso werden Rekurrente Neuronale Netzwerke (RNN) untersucht, da sie sich besonders gut für Zeitreihenvorhersagen eignen. Darüber hinaus wird gezeigt, wie ein solcher Prädiktionsansatz durch Kartendaten für den Fall einer a priori bekannten Route erweitert werden kann. Dabei wird ebenso geprüft, ob die Vorhersagegenauigkeit verbessert werden kann, wenn sowohl Kartendaten verfügbar, als auch die aktuelle Position (beispielsweise mittels globalem Navigationssatellitensystem, kurz GNSS) bekannt sind. Die grundsätzliche Funktionsweisen dieser Verfahren wurden bereits im *Stand des Wissens* in Kapitel 3.4.2 eingeführt.

6.1.1 Markov-Ketten (MC)

Analog zur Fahrzyklengenerierung in [Sil16a, För20] wird jeder Zustand durch ein 3×1 Tupel dargestellt, das aus der Fahrzeuggeschwindigkeit v_i , Fahrzeugbeschleunigung a_i , und Fahrbahnsteigung α_i besteht (Formel 6.1):

$$S_i = [v_i \quad a_i \quad \alpha_i] \quad (6.1)$$

Wird die Fahrbahnsteigung nicht berücksichtigt, reduziert sich der Zustand S_i auf ein 2×1 Tupel. Um mit den MC drehmomentrelevante Größen vorhersagen zu können, muss zunächst die Übergangswahrscheinlichkeitsmatrix (TPM) aus den Trainingsdaten berechnet werden. Die Anwendung der MC erfolgt schließlich mittels der *dtmc*-Funktion aus der *MATLAB Econometrics Toolbox* (vgl. Deufel et al. [1]). Die Diskretisierung der Größen wird durch umfangreiche Parameterstudien erarbeitet, welche in Anhang J sowie Deufel et al. [1] näher beschrieben werden.

6.1.2 Vorwärtsgerichtete Neuronale Netzwerke (FFNN)

Bei der Modellierung des FFNN werden die Eingänge und Ausgänge analog zu [Xie18a] gewählt, siehe Abbildung 6.1. Dabei repräsentieren die Eingänge

den betrachteten Zeithorizont in der Vergangenheit, während die Ausgänge den vorhergesagten Zeithorizont in der Zukunft darstellen. Die Anzahl der Ein- und Ausgänge werden im Rahmen der Untersuchungen gleich gewählt, sodass ein Vorhersagehorizont in die Zukunft von 20 s auch eine Berücksichtigung der letzten 20 s erfordert. Im Gegensatz zur MC wird keine explizite Modellierung der Fahrzeugbeschleunigungen vorgenommen, da die Fahrzeugbeschleunigungen hier bereits indirekt durch die Fahrzeuggeschwindigkeitsabfolge berücksichtigt werden. Im Rahmen der Arbeit werden die Anzahl der versteckten Schichten mit N_{HL} bezeichnet, die Anzahl der Neuronen in der Eingangsschicht mit $N_{neurons,IL}$, die Anzahl der Neuronen in der Ausgangsschicht mit $N_{neurons,OL}$ und die Anzahl der Neuronen in den versteckten Schichten i mit $N_{neurons,HL,i}$ (vgl. Deufel et al. [1]).




Abbildung 6.1: FFNN zur Vorhersage von Fahrzeuggeschwindigkeit, Fahrzeugbeschleunigung und Fahrbahnsteigung, aus Deufel et al. [1].

Das FFNN ist in *python* mit der Bibliothek *Keras* implementiert. *Keras* ist eine Bibliothek für ANN, die auf der *TensorFlow*-Plattform aufbaut. Die Anzahl der versteckten Schichten und die Anzahl der Neuronen, die Verlustfunktion, die Aktivierungsfunktion und andere Parameter werden

durch umfangreiche Studien festgelegt. Als Aktivierungsfunktion wird die Rectified Linear Unit (ReLU) gewählt, als Verlustfunktion der Mittlere Quadratische Fehler (engl. *Mean Squared Error*, kurz MSE), vgl. Deufel et al. [1]. Für weitere Informationen sei auf Anhang J und Deufel et al. [1] verwiesen.

6.1.3 Rekurrente Neuronale Netzwerke (RNN)

Im Rahmen der Arbeit wird ein Rekurrentes Neuronales Netzwerk (RNN) mit langem Kurzzeitgedächtnis (LSTM) eingesetzt. Zur Realisierung multivariater, mehrstufiger Zeitreihenvorhersagen wird eine Konfiguration mit Encoder und Decoder (im Folgenden kurz ED-LSTM genannt) angewandt, welche analog zum vorherigen Abschnitt in *Keras* umgesetzt wird. Multivariat bedeutet, dass mehrere Variablen als Input für die Analyse berücksichtigt werden. Mehrstufig bedeutet, dass mehrere Zeitschritte vorhergesagt werden. Die Verwendung einer Encoder-Decoder-Konfiguration bietet die Möglichkeit, die Länge von Eingangs- und Ausgangssequenz unterschiedlich zu wählen. Dies kann beispielsweise von Vorteil sein, wenn ein längerer Zeithorizont als Eingang als zur Ausgabe berücksichtigt werden soll. Ein ED-LSTM besteht aus drei Komponenten: Encoder, Zwischenvektor und Decoder. Sowohl der Encoder als auch der Decoder enthalten mehrere LSTMs. Der Encoder liest die Eingabesequenz und fasst die versteckten Zustands- und Zellzustandsinformationen zusammen. Die Ausgabe des Encoders ist ein Vektor fester Länge, der angibt, wie das Modell die Sequenz interpretiert. Die erste Zelle des Decoder-Netzwerks erhält den Vektor von der letzten Zelle des Encoders. Für jeden Zeitschritt errechnet der Decoder schließlich die Ausgabe y_t [Sut14, Gan18, Cha21]. Ein vereinfachtes Schema des entwickelten ED-LSTM für die Prädiktion des Fahrgeschwindigkeitsprofils ist in Abbildung 6.2 zu sehen. Dabei stellen $f_{gTS,k}$, $f_{gGW,k}$, $f_{gCV,k}$ jeweils Flags für das Vorhandensein einer Ampel, eines Vorfahrt-gewähren-Schildes oder einer Kurve zum Zeitpunkt k dar. v_k und v_{max_k} stehen für die Fahrzeuggeschwindigkeit bzw. die zulässige Höchstgeschwindigkeit zum Zeitpunkt k . Analog gibt α_k die Fahrbahnsteigung zum Zeitpunkt k wieder (vgl. Deufel et al. [3]).

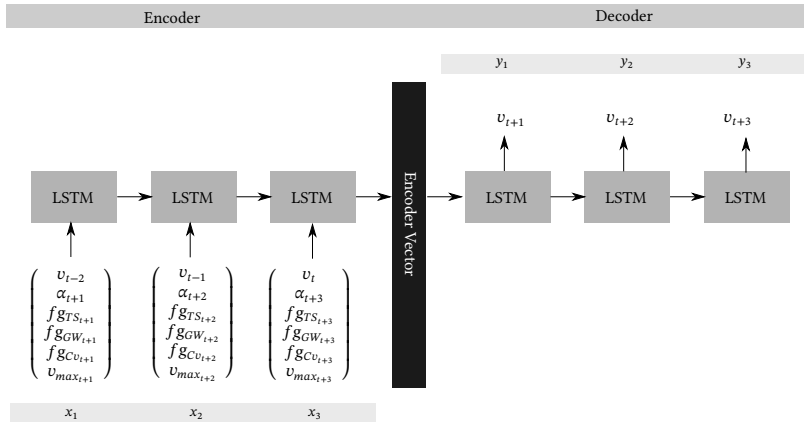


Abbildung 6.2: Architektur des entwickelten ED-LSTM in einer mehrstufigen, multivariaten Anwendung für einen beispielhaften Vorhersagehorizont von 3 s. Aus Deufel et al. [3].

Die Ausgabe des ED-LSTM stellt in diesem Beispiel die zukünftige Fahrzeuggeschwindigkeit für den Vorhersagehorizont von 3 s dar. Bei den Eingabedaten besteht jeder Zustand aus der vergangenen und gegenwärtigen Fahrzeuggeschwindigkeit sowie den zu diesem Zeitpunkt bereits bekannten zukünftigen Kartendaten. Die Ausgabe des ED-LSTM ist eine Ergebnismatrix mit den prognostizierten Fahrgeschwindigkeiten für die folgenden Zeitschritte. Im Rahmen der Modellierung wird davon ausgegangen, dass die zuletzt bekannten Fahrzeuggeschwindigkeiten in Kombination mit den zukünftigen Streckeninformationen die bestmögliche Bestimmung des zukünftigen Fahrzeuggeschwindigkeitsprofils ermöglichen. Wie bereits erwähnt, können die Längen der Ein- und Ausgänge bei der Anwendung von ED-LSTMs unterschiedlich sein. Im Rahmen dieser Arbeit haben die Eingänge jedoch die gleiche Länge wie die Ausgänge. Mit anderen Worten: Für eine Vorhersage von 20 s in die Zukunft werden analog zu FFNN vergangene Fahrzeuggeschwindigkeitswerte einer Zeitspanne von 20 s herangezogen. Die geeignete Anzahl der LSTM-Einheiten wird durch Parameterstudien

bestimmt, die an dieser Stelle nicht weiter diskutiert werden. In dieser Arbeit entspricht die Anzahl der LSTM-Einheiten der Anzahl der Zeitschritte, die vorhergesagt werden. Außerdem wird, ähnlich wie bei FFNN, eine Aktivierungsfunktion benötigt, wobei weiterhin die Rectified Linear Unit (ReLU) gewählt wird. Als Verlustfunktion wird analog zu FFNN der mittlere quadratische Fehler (MSE) berechnet. Die endgültige Parametrierung einschließlich Lernrate, Batchsize, Epochen und gewähltem Optimierer ist Anhang J zu entnehmen (vgl. Deufel et al. [3]).

Nachdem die entwickelten Methodiken zur Vorhersage der notwendigen, drehmomentrelevanten Größen nun vorgestellt wurden, werden im folgenden Kapitel die jeweiligen Prädiktionen diskutiert.

6.2 Vergleich und Diskussion der Prädiktionen

Die Prädiktionsgenauigkeiten der drei vorgestellten Verfahren werden sowohl durch qualitative als auch quantitative Analysen diskutiert. Nachfolgend sind exemplarisch die Prädiktionen von MC, FFNN und RNN in ED-LSTM Konfiguration im Zeitbereich dargestellt.

Markov-Ketten (MC)

Wie in Abbildung 6.3 gezeigt, lassen sich mit MC sowohl eine Fahrzeuggeschwindigkeit als auch eine Fahrzeugbeschleunigung vorhersagen, wobei die aus der integrierten Fahrzeugbeschleunigung resultierende Fahrzeuggeschwindigkeit einen etwas geringeren RMSE zwischen prädizierter und tatsächlich gefahrener Fahrzeuggeschwindigkeit aufweist. Generell zeigen MC die beste Vorhersagegenauigkeit in Bereichen mit geringer Dynamik. Bei einem Fahrzeugbeschleunigungsmanöver hingegen, wie es bei $t = 80$ s auftritt, wird der Übergang zu einer relativ konstanten Fahrzeuggeschwindigkeit erst dann richtig vorhergesagt, wenn die Maximalgeschwindigkeit fast erreicht ist. Ähnlich verhält es sich bei der Verzögerung bei $t = 260$ s,

die erst nach Beginn des Bremsvorgangs richtig erkannt wird. Auch der Anfahrvorgang konnte erst nach dem Anstieg der Fahrzeuggeschwindigkeit ($t = 290$ s) vorhergesagt werden. Solange die Fahrzeuggeschwindigkeit $v = 0$ beträgt, wird auch eine Fahrzeuggeschwindigkeit von $v = 0$ vorhergesagt. Insgesamt sind die Prädiktionen der MC jedoch nachvollziehbar und somit als plausibel einzustufen (vgl. Deufel et al. [1]).




Abbildung 6.3: Vorhersagen mit MC ohne Fahrbahnsteigung aus Deufel et al. [1]. Dargestellt an einem exemplarischen Fahrzyklus aus dem *Alternativen Datensatz* (Abbildung H.1).

Für die Voraussagen unter Berücksichtigung der Fahrbahnsteigung sei auf Deufel et al. [1] verwiesen. Hier enthalten sind auch weitere quantitative Analysen.

Vorwärtsgerichtete Neuronale Netzwerke (FFNN)

Das FFNN zeigt grundsätzlich eine ähnliche Performance wie MC (Abbildung 6.4). Auch hier werden Beschleunigungs- bzw. Verzögerungsphasen erst dann vorhergesagt, wenn sie bereits eingeleitet sind ($t = 530$ s). Die Vorhersagen können jedoch deutlich voneinander abweichen: Während die

MC in Abbildung 6.3 bei $t = 310$ s tendenziell einen höheren Fahrzeuggeschwindigkeitsanstieg erwartet als tatsächlich eintritt, geht das FFNN in Abbildung 6.4 in einer vergleichbaren Fahrphase bei $t = 1050$ s von einem geringeren Fahrzeuggeschwindigkeitsanstieg aus. Ebenso wird in Abbildung 6.3 bei $t = 290$ s, wie bereits erwähnt, ein weiterer Stillstand erwartet, während das FFNN in einer ähnlichen Situation in Abbildung 6.4 bei $t = 120$ s stets einen Beschleunigungsvorgang prädiziert. Das letztgenannte Beispiel zeigt die grundlegend unterschiedliche Funktionsweise der Verfahren MC und FFNN. Im Falle des Stillstands ist der wahrscheinlichste Folgezustand ein weiterer Stillstand (der Anfahrvorgang findet nur in einem einzigen Zeitschritt statt) und die TPM der MC wird entsprechend trainiert. Bei FFNN werden jedoch nicht die tatsächlich aufgetretenen Zustandsübergänge betrachtet, aus denen eine Übergangswahrscheinlichkeit berechnet wird. Das Netz wird stattdessen lediglich auf den niedrigsten mittleren quadratischen Fehler (MSE) insgesamt trainiert (vgl. Deufel et al. [1]).




Abbildung 6.4: Vorhersagen mit FFNN ohne Fahrbahnsteigung aus Deufel et al. [1]. Dargestellt an einem exemplarischen Fahrzyklus aus dem *Alternativen Datensatz* (Abbildung H.1).

Insgesamt lässt sich festhalten, dass bei der qualitativen Analyse die Vorhersagen von MC und FFNN ähnlich abschneiden. Sowohl MC als auch FFNN

können das Fahrgeschwindigkeitsprofil nur bedingt vorhersagen. Dynamische Veränderungen im gefahrenen Profil können ohne weitere Maßnahmen erst dann berücksichtigt werden, wenn sie bereits eingeleitet wurden. Allerdings gibt es individuelle Vor- und Nachteile der jeweiligen Vorhersagen, die sich durch grundlegende Unterschiede in den Modellarchitekturen erklären lassen. Die quantitativen Analysen zeigen, dass FFNN $\approx 30\%$ genauere Fahrzeuggeschwindigkeitsvorhersagen erreichen können und insgesamt zu einer höheren Genauigkeit im Vergleich zu MC führen, insbesondere dann, wenn die Fahrbahnsteigung berücksichtigt wird. Darüber hinaus zeigen MC bei größeren Vorhersagehorizonten einen überproportionalen Anstieg des Fehlers zwischen realen und prädizierten Größen im Gegensatz zu FFNN (vgl. Deufel et al. [1]). Entsprechend den weiterführenden Untersuchungen in Deufel et al. [1] kann eine Verbesserung der Vorhersagequalität durch Berücksichtigung der Fahrbahnsteigung weder für MC noch für FFNN festgestellt werden. Zusammenfassend lässt sich sagen, dass ein FFNN einer MC vorzuziehen ist (vgl. Deufel et al. [1]).

Rekurrente Neuronale Netzwerke (RNN)

Aufgrund der identifizierten Vorteile von FFNN als Vertreter der ANN werden in einem weiteren Schritt RNN in der beschriebenen ED-LSTM Konfiguration verwendet. Mit Blick auf die identifizierten Grenzen hinsichtlich der Erkennung dynamischer Ereignisse (Anhalten, Anfahren, usw.) wird dabei zusätzlich untersucht, inwiefern bei Bekanntheit der Route die aus Kartendaten bezogenen Zusatzinformationen die Prädiktionen verbessern können. In diesem Fall kann auch die Fahrbahnsteigung aus Kartendaten bestimmt werden. Die Fahrzeugbeschleunigung wird weiterhin durch numerische Differenzierung aus dem Fahrzeuggeschwindigkeitsprofil abgeleitet. In Abbildung 6.5 (oben) sind die relevanten Kartendaten für einen Abschnitt einer bestimmten Strecke als Flag im Zeitverlauf dargestellt. Dies umfasst Kurven (grau), Ampeln (violett) und Vorfahrt gewähren (gelb). Darüber hinaus wird im unteren Teil der Abbildung die zulässige Höchstgeschwindigkeit aus den Kartendaten aufgetragen (rote Linie). Ebenso ist das entsprechende reale Fahrgeschwindigkeitsprofil dargestellt (blaue Linie). Die Vorhersagen des ED-LSTM sind durch eine hellgraue und eine dunkelgraue Linie dargestellt, jeweils für einen Vorhersagehorizont von 20 s. Die hellgrauen Linien stellen Vorhersagen ohne Kenntnis

der Kartendaten dar. Die dunkelgrauen Linien stellen Vorhersagen mit Kartendaten dar (vgl. Deufel et al. [3]).




Abbildung 6.5: Beispielhafte Testsequenz mit ED-LSTM bei 20 s Vorhersagehorizont. Aus Deufel et al. [3]. Dargestellt an einem exemplarischen Fahrzyklus aus dem *Alternativen Datensatz* (Abbildung H.1).

Der Einfluss der aus Kartendaten gewonnenen Informationen auf das Fahrzeuggeschwindigkeitsprofil (blaue Linie) ist in Abbildung 6.5 deutlich zu erkennen. Bei $t = 120$ s werden sowohl ein Vorfahrt-gewähren-Schild als auch eine Kurve erkannt. Obwohl das Fahrzeug nicht anhält, führt die Kurve zu einer Fahrzeuggeschwindigkeitsreduzierung auf ≈ 30 km/h. Auch bei $t = 180$ s wird die Fahrzeuggeschwindigkeit des Fahrzeugs reduziert. Ein Stopp aufgrund der Ampel bei $t = 200$ s ist jedoch nicht erkennbar. Es ist unklar, ob die Fahrzeuggeschwindigkeitsreduzierung aus der Kurve resultiert oder aus einem Rückstau der roten Ampel, die gerade wieder auf Grün geschaltet hat. Der gemessene Fahrzeuggeschwindigkeitsverlauf wird also durch verkehrsbedingte Fahrzeuggeschwindigkeitsanpassungen, die in der Prognose nicht berücksichtigt werden können, beeinflusst. Bei $t = 340$ s ist die Ampel grün und hat somit keinen Einfluss auf das Fahrzeuggeschwindigkeitsprofil. Bei $t = 280$ s und $t = 380$ s gibt es einen Stopp aufgrund der erkannten Ampel. Eine Analyse der Bremsmanöver zeigt, dass das ED-LSTM mit Kenntnis von Kartendaten ein Bremsmanöver wesentlich genauer vorhersagen kann, als ohne Kenntnis

der Kartendaten. Dies ist besonders gut in den Fahrsituationen bei $t = 120$ s, $t = 180$ s, $t = 280$ s und $t = 380$ s zu sehen (grüne Kreise). Das ED-LSTM ohne Kenntnis der Kartendaten prognostiziert in allen Fahrsituationen ein Fahrzeuggeschwindigkeitsprofil ohne größere Dynamik (hellgraue Linien). Das ED-LSTM mit Kenntnis der Kartendaten sagt dagegen ein Bremsmanöver voraus, sobald der jeweilige Flag in den Vorhersagehorizont des ED-LSTM (20 s) gerückt ist (vgl. Deufel et al. [3]). Insgesamt konnte in Deufel et al. [3] mittels der qualitativen Analysen des ED-LSTM bestätigt werden, dass die identifizierten Kartendaten korrekt eingehen und dynamische Ereignisse hierdurch besser in den Prädiktionen berücksichtigt werden. Bei den quantitativen Analysen in Deufel et al. [3] wird im Hinblick auf die RMSE-Werte von Fahrzeuggeschwindigkeit und Fahrzeugbeschleunigung deutlich, dass ED-LSTMs durchweg besser abschneiden als FFNN. Diese Beobachtung steht im Einklang mit der weit verbreiteten Auffassung, dass RNN für die Vorhersage von Zeitreihen besser geeignet sind. Bei der Verwendung von Kartendaten kann eine zusätzliche Verringerung der RMSE-Werte erreicht werden. Für weiterführende Informationen sei auf die Veröffentlichungen von Deufel et al. [1] und [3] verwiesen.

Zusammenfassend lässt sich sagen, dass das ED-LSTM gegenüber MC und FFNN vorzuziehen ist. Weitere Arbeiten sollten sich damit beschäftigen, wie das ED-LSTM mit zusätzlichen Informationen angereichert werden kann, um die Vorhersagen präziser zu machen. Eine einfache Erweiterung besteht in der Verwendung von Radar-, Lidar- und Kameradaten oder zusätzlichen Daten von Car-to-Car-(C2C)- oder Car-to-X-(C2X)-Kommunikation, wenn diese zugänglich sind. Dies dürfte die Vorhersage von Stillstandsphasen erleichtern, die nicht durch Kartendaten erklärt werden können. Ebenso ermöglicht beispielsweise die Kenntnis des Ampelzustands eine spezifischere Vorhersage, ob auch tatsächlich ein Anhaltevorgang zu erwarten ist (vgl. Deufel et al. [3]).

Nachdem die entwickelten Methodiken zur Vorhersage der notwendigen, drehmomentrelevanten Größen nun vorgestellt und die jeweiligen Prädiktionen diskutiert wurden, werden im Folgekapitel zwei Konzepte für eine

prädiktive Online-ECMS vorgestellt. Dabei soll die Berücksichtigung solcher Prädiktionen diskutiert werden.

6.3 Konzeption einer prädiktiven Online-ECMS

Nachfolgend werden zwei Konzepte aufgezeigt, wie die entwickelte, nicht-prädiktive Online-ECMS durch prädiktive Informationen erweitert werden kann. Dabei wird ein grundsätzliches Verständnis dafür entwickelt, durch welche Mechanismen bei einer prädiktiven Online-ECMS - losgelöst von der Unschärfe der eigentlichen Prädiktion - zusätzliche Kraftstoffeinsparpotentiale erzielt werden können. Bei *Ansatz 1* werden *Precient* Prädiktionen verwendet (vgl. Unterteilung nach [Još18] in Abschnitt 3.4.1), bei denen der zukünftige Geschwindigkeits- und Steigungsverlauf a priori perfekt bekannt ist. Unter Zuhilfenahme eines Längsdynamikmodells kann damit auch der Drehmomentbedarf ermittelt werden. Zusätzlich wird ein weiterer Ansatz vorgestellt (*Ansatz 2*), bei dem gezeigt wird, wie bei Kenntnis der Route einzig durch die Berücksichtigung relevanter Kartendaten Kraftstoffeinsparpotentiale möglich sind. In einem abschließenden Zwischenfazit wird geprüft, inwieweit eine Weiterentwicklung der vorgestellten Konzepte - ggf. durch Kopplung mit den Prädiktionsmechanismen aus Kapitel 6.2 - zu einer gesamtheitlichen, prädiktiven Online-ECMS sinnvoll ist.

Ansatz 1: Berücksichtigung des zukünftigen Raddrehmoments

Entsprechend der Ausführungen im Grundlagenkapitel bestimmt eine ECMS grundsätzlich den bestmöglichen Betrieb aus allen Betriebsarten durch Auffinden des minimalen äquivalenten Kraftstoffverbrauchs [Gör16, Ono16]. Manche Betriebsarten werden jedoch nach vorgegebenen Regeln und nicht von der ECMS bestimmt und sind somit auch nicht Teil des Optimierungsproblems. Ein Beispiel hierfür ist der Rekuperationsbetrieb: Solange die Komponentengrenzen nicht überschritten werden und ausreichend Puffer in der Batterie vorhanden ist, wird stets rekuperiert. Im Rahmen dieser

Arbeit erfolgt dies durch die in Kapitel 5.1.2 beschriebene Implementierung der ECMS, wobei sich λ_{eff} entsprechend Formel 5.2 gleichzeitig verringert, um einen ladungserhaltenden Betrieb sicherzustellen. Der entwickelte Ansatz einer prädiktiven Online-ECMS stützt sich nun auf folgende Idee: Basierend auf dem prädizierten Geschwindigkeits-, Beschleunigungs- und Steigungsprofil (vgl. Abbildung 3.4) wird mit Hilfe eines einfachen Längsdynamikmodells (Formeln 2.1-2.5) der Drehmomentbedarf innerhalb des Prognosehorizonts ermittelt (sofern direkt ein Drehmoment prädiziert wurde, kann dieser Schritt entfallen). Damit lässt sich auch auf das resultierende Rekuperationspotential am Rad schließen. Unter Vernachlässigung des Wirkungsgrades des Antriebsstrangs ergibt sich daraus ein Maß für den anstehenden SOC-Anstieg innerhalb des Vorhersagehorizonts. Entsprechend dieser prognostizierten Zunahme des Batterieladezustands wird der Wert der elektrischen Energie, also der Wert des Äquivalenzfaktors λ , durch die Einführung eines zusätzlichen Terms $k p_{pred} \cdot p_{recu}$ präventiv abgesenkt (Formel 6.2). Die Formel 5.2 wird hierzu erweitert, wobei p_{recu} für das Rekuperationspotential im Prognosehorizont in Wh steht. $k p_{pred}$ ist ein zu parametrierender Proportionalitätsfaktor zur Berücksichtigung des Rekuperationspotentials (Deufel et al. [2]):

$$\lambda_{eff}(t) = \lambda_{0,avg} - k p_{SOC} \cdot \Delta SOC_{CS}(t)^3 - k p_{pred} \cdot p_{recu}(t) \quad (6.2)$$

Zusätzlich wird der Parameter E_{min} eingeführt, der die Mindestmenge an Energie angibt, ab der eine Adaption von λ erfolgt. Ebenso muss der Prädiktionshorizont selbst passend gewählt werden. Wie beschrieben, führt ein niedrigeres λ zu einer Verringerung des Wertes der elektrischen Energie im Optimierungsproblem. Infolgedessen wird die Batterie eher entladen. Insbesondere bei kleinen Batterien können Rekuperationspotentiale aus dem Fahrzyklus so besser genutzt und die Batteriegrenzen weiterhin eingehalten werden. Durch den optimalen Einsatz dieser zurückgespeisten elektrischen Energie können in der Konsequenz zusätzliche Kraftstoffeinsparungspotentiale erzielt werden. Die Einflüsse durch die prädiktive Online-ECMS bei einer Variation des Prädiktionshorizonts oder Änderung der Mindestenergiemenge sind nachfolgend dargestellt (vgl. Deufel et al. [2]).

Einfluss durch Variation des Vorhersagehorizonts τ_{pred}

Abbildung 6.6 zeigt den Einfluss eines kleinen (10 s) und eines großen (50 s) Vorhersagehorizonts anhand zweier Sequenzen. In beiden Fällen ist der Verlauf des Batterieladezustands sowie die Fahrgeschwindigkeit aufgetragen. Zusätzlich wird im linken Fall das Raddrehmoment aufgezeichnet. Im rechten Fall ist das Drehmoment des Verbrennungsmotors dargestellt (vgl. Deufel et al. [2]).

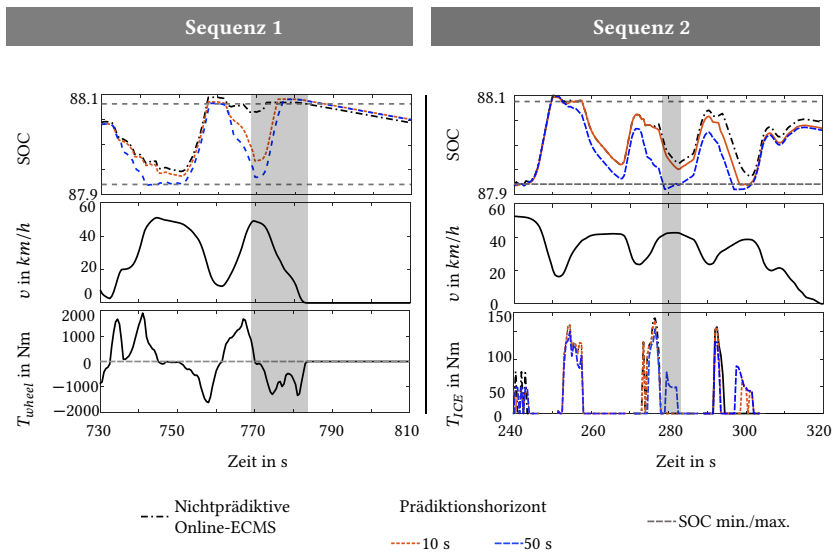


Abbildung 6.6: Analyse eines unterschiedlichen Vorhersagehorizonts der prädiktiven Online-ECMS für zwei beispielhaften Sequenzen. Aus Deufel et al. [2]. Die Sequenzen sind dem Realfahrzyklus *urban low mild* (Realfahrzyklus Nr. 3 aus Abbildung 2.7) entnommen.

Wie in *Sequenz 1* dargestellt, ist eine Berücksichtigung des Rekuperationspotentials mit einem Zeithorizont von 10 s zum Zeitpunkt $t = 770$ s nur eingeschränkt möglich. Die Batterie wird nur unzureichend entladen, so dass die

obere Batteriegrenze SOC_{max} bereits zu einem frühen Zeitpunkt der Rekuperationsphase erreicht wird (rote Linie im SOC-Verlauf). Um das Rekuperationspotential aus der Verzögerung besser zu berücksichtigen, sollte ein größerer Vorhersagehorizont von 50 s berücksichtigt werden (blau gestrichelte Linie im SOC-Verlauf). Andererseits kann bei *Sequenz 2* ein Vorhersagehorizont von 50 s auch dazu führen, dass Rekuperationspotentiale zu früh in der prädiktiven Online-ECMS berücksichtigt werden. Zum Zeitpunkt $t = 280$ s beispielsweise muss die VKM aktiviert werden, da das anstehende Rekuperationspotential bereits zu früh berücksichtigt wird und zu einer zu starken Entladung führt. Dies führt in der Konsequenz zu einem Anstieg des Kraftstoffverbrauchs. Insgesamt lässt sich festhalten, dass der gewählte Vorhersagehorizont einen großen Einfluss auf die EMS hat (vgl. Deufel et al. [2]).

Einfluss durch Variation des Schwellenwerts E_{min}

Im Folgenden wird die Einführung eines Schwellenwerts erörtert. Dafür ist in Abbildung 6.7 der effektiv wirkende λ_{eff} und der Batterieladezustand SOC über der Zeit aufgetragen. Links ist nur λ_{eff} , sowohl für eine prädiktive Online-ECMS als auch für eine nichtprädiktive Online-ECMS ohne Schwellenwert dargestellt. Auf der rechten Seite sind die gleichen Größen mit eingeführtem Schwellenwert zu sehen. Zusätzlich wird für den Fall mit Schwellenwert auf der rechten Seite der SOC aufgezeigt. Die Berücksichtigung des Rekuperationspotentials durch Einführung des Terms $kp_{pred} \cdot p_{precu}$ (Formel 6.2) führt zu einer durchgehenden Verringerung von λ im Vergleich zur nichtprädiktiven Online-ECMS ohne weitere Maßnahmen. Dies würde zu einem vermeidbaren Kraftstoffmehrverbrauch führen, wie im Folgenden erläutert wird. Nach [Wah15, Gör16, Ono16] führt ein konstantes λ im Falle zeitinvarianter Eigenschaften der Batterie zu einer kraftstoffoptimalen Steuerung, wenn es iterativ wie in Abschnitt 3.3 beschrieben, bestimmt wird. Der vorgestellte Entwurf einer nichtprädiktiven Online-ECMS enthält einen Durchschnittswert $\lambda_{0,avg}$ der Offlinelösungen für λ_0 über die zwölf Realfahrzyklen. Das effektiv in der Online-ECMS wirkende λ_{eff} berechnet sich dann durch die Korrektur von $\lambda_{0,avg}$ über kp_{SOC} , um einen ladungserhaltenden Betrieb bei der Online-ECMS zu gewährleisten (vgl. Deufel et al. [2]).




Abbildung 6.7: Analyse der Einführung eines Schwellenwerts für die prädiktive Online-ECMS beim Realfahrzyklus *urban low mild* (Realfahrzyklus Nr. 3 aus Abbildung 2.7): Die nichtprädiktive Online-ECMS ist in schwarz dargestellt, die prädiktive Online-ECMS in orange. Eine Berücksichtigung des Rekuperationspotentials, wie in Formel 6.2 eingeführt, führt ohne Schwellenwert zu einer kontinuierlichen Verringerung von λ für die prädiktive Online-ECMS (orange). Mit Schwellenwert sind jedoch gezielte Entladungen realisierbar, vgl. SOC-Verlauf, rechts. Aus Deufel et al. [2].

Obgleich im Onlinebetrieb gegenüber der Offline-ECMS nach dem PMP, wie bereits erwähnt, keine optimale Lösung bestimmt werden kann, führt die adäquate Anpassung von $\lambda_{0,avg}$ zu Ergebnissen, die sich nahe am Optimum bewegen, vgl. Abschnitt 5. Im Falle einer durchgehenden Reduktion weicht λ_{eff} jedoch stets signifikant von $\lambda_{0,avg}$ ab. Aufgrund des stets zu niedrigen λ bei der Bestimmung der äquivalenten Leistung im Optimierungsproblem (vgl. Kapitel 3.3) wird die Batterie permanent zu sehr entladen. Der SOC bewegt sich insgesamt zu nahe an der unteren Batteriegrenze SOC_{min} , was zu einem Anstieg des Kraftstoffverbrauchs aufgrund der eingeschränkten Hybridfunktionalität führt. Die durchgehende Verringerung von λ kann durch die Einführung eines Schwellenwerts E_{min} vermieden werden. Damit ist für einen Eingriff in die Lambdaberechnung eine Mindestmenge an rekuperierbarer Energie E_{min} erforderlich (siehe Abbildung 6.7, mittleres Diagramm). Eine Adaption von λ erfolgt somit nur dann, wenn so viel Rekuperationspotential zu erwarten ist, dass die zusätzliche Abweichung vom gemittelten λ_0 -Wert durch das aus $k p_{pred} \cdot p_{recu}$ resultierende Kraftstoffeinsparpotential überkompensiert

wird. Insgesamt bleiben die resultierenden SOC-Trajektorien weitestgehend identisch; siehe Abbildung 6.7, rechts. Der Einfluss der prädiktiven Online-ECMS ist im SOC-Verlauf jedoch deutlich zu erkennen, vgl. Diagramm bei $t = 1600$ s (siehe Abbildung 6.7, Zoomansicht rechtes Diagramm). Entsprechend Deufel et al. [2].

Im Rahmen der Arbeit von Deufel et al. [2] werden für einen P14-Hybrid mit einer 25 Wh-Batterie Parameterstudien durchgeführt und die ideale Parametrierung für die prädiktive Online-ECMS festgelegt. Die Ergebnisse zeigen merkbare Reduktionspotentiale im Vergleich zur nichtprädiktiven Online-ECMS:

- Eine einheitliche Parametrierung über alle zwölf Realfahrzyklen führt zu Einsparpotentialen von bis zu 1.65 % beim Realfahrzyklus *urban low mild* (Realfahrzyklus Nr. 3 aus Abbildung 2.7). In einzelnen Fahrzyklen kann es jedoch zu einem leichten Anstieg des Kraftstoffverbrauchs kommen. Bei einer Gleichgewichtung aller Einsparpotentiale ist ein durchschnittliches Einsparpotential von 0.4 % zu erwarten (vgl. Deufel et al. [2]).
- Bei fahrzyklusspezifischer Parametrierung steigen die Einsparpotentiale auf bis zu 2.32 % im Vergleich zur nichtprädiktiven Online-ECMS. Im Durchschnitt ist hier ein Einsparpotential von 0.7 % zu erwarten. Für eine Anwendung der individuellen Parametrierung sind weitere Algorithmen notwendig, um einen Einsatz im realen Fahrzeug zu ermöglichen (vgl. Deufel et al. [2]).

Es wurde somit nachgewiesen, dass bei der Wahl einer kleinen Batterie im Antriebsstrang eine prädiktive Online-ECMS im Vergleich zu einer robusten, nichtprädiktiven Implementierung Einsparpotentiale im Kraftstoffverbrauch erzielen kann. Im Rahmen weitere Untersuchungen könnte eine Abhängigkeit von kp_{pred} vom Batterieladezustand eingeführt werden. Wenn der Ladezustand der Batterie zum Zeitpunkt k bereits den SOC_{min} erreicht hat, ist keine weitere Verringerung des Wertes der elektrischen Energie via λ zulässig. Außerdem wäre eine Abhängigkeit von kp_{pred} vom Auftreten

des Erholungspotentials im Prognosehorizont denkbar. Tritt die Rekuperation früh im Zeithorizont auf, wird ein großer Einfluss angestrebt. Tritt die Rekuperation spät im Zeithorizont auf, soll ein kleiner Einfluss realisiert werden. Darüber hinaus soll der prädiktive Online-ECMS-Algorithmus durch die Berücksichtigung von längeren E-Drive- oder Stehphasen weiterentwickelt werden: Wenn der Drehmomentbedarf kleiner als die übliche Mindestschwelle für die Aktivierung des Verbrennungsmotors ist, erfolgen Traktion und Versorgung der Nebenverbraucher rein aus dem elektrischen Energiespeicher (vgl. Deufel et al. [2]). Für weiterführende Informationen wird auf Deufel et al. [2] verwiesen.

Ansatz 2: Berücksichtigung von Ampelpositionen

Alternativ zum vorangegangenen Ansatz wird in Deufel et al. [4] aufgezeigt, wie durch Kartendaten ohne explizite Prädiktion des Drehmoments Einsparpotentiale im Vergleich zur nichtprädiktiven Online-ECMS erzielt werden. Eine beispielhafte Umsetzung dieser Methodik erfolgte bereits in [S8], obgleich das grundlegende, nachfolgend beschriebene Konzept einer prädiktiven Online-ECMS dem Autor dieser Dissertation zuzuschreiben ist. Dabei hat das Auftreten einer Ampel (repräsentiert durch fg_{TS}) innerhalb des festgelegten Horizonts direkten Einfluss auf λ_{eff} durch einen zusätzlichen Parameter kp_{TS} (vgl. Deufel et al. [4]). Basierend auf Formel 5.2 ergibt sich folgende Formulierung (Formel 6.3):

$$\lambda_{eff}(t) = \lambda_{0,avg} - kp_{SOC} \cdot \Delta SOC_{CS}(t)^3 - kp_{TS} \cdot fg_{TS}(t) \quad (6.3)$$

Dabei konnte in Deufel et al. [4] für ausgewählte Fahrzyklen mit hoher Ampeldichte gezeigt werden, wie sich auch hier Einsparpotentiale gegenüber einer nichtprädiktiven Implementierung erzielen lassen. Entscheidend ist dabei, dass das Vorhandensein von Ampeln typischerweise zu Rekuperationsereignissen führt, während Ampelsituationen ohne Auswirkung auf das Fahrgeschwindigkeitsprofil in der Unterzahl sind. Mit anderen Worten: Trotz einzelner λ -Reduktionen ohne tatsächliche Bremsereignisse im Falle einer grünen Ampel ergibt sich ein Gesamtnutzen durch die prädiktive Online-ECMS im Vergleich zur nichtprädiktiven Online-ECMS. Die höchsten

Einsparpotentiale zeigen sich bei *Ansatz 2* für einen nutzbaren Batterieenergieinhalt von 100 Wh. Bei geringeren nutzbaren Energiegehalten der Batterie E_{bat} sinken die Einsparpotentiale durch eine prädiktive Implementierung. Für größere Batterien können im Rahmen der Untersuchungen keine signifikanten Einsparpotentiale bei Anwendung der prädiktiven Online-ECMS nachgewiesen werden, da die Batterie groß genug ist, um die durch Rekuperation zurückgewonnene Energie auch ohne Vorkonditionierung des Ladezustands vollständig aufzunehmen. Analog zu Kapitel 6.2 könnte die vorgestellte prädiktive Online-ECMS durch die Verwendung von Karten-, Radar-, Lidar- und Kamerainformationen sowie Telemetriedaten aus der C2C- und C2X-Kommunikation, z. B. hinsichtlich des Ampelstatus erweitert werden (vgl. Deufel et al. [4]). Für weiterführende Informationen wird auf Deufel et al. [4] verwiesen.

Nachdem Methodiken zur Vorhersage der notwendigen, drehmomentrelevanten Größen vorgestellt, die jeweiligen Prädiktionen diskutiert wurden und außerdem Konzepte für eine prädiktive Online-ECMS vorgestellt wurden, soll nun ein abschließendes Zwischenfazit zum Forschungsfeld *Potentiale prädiktiver EMS* gezogen werden.

6.4 Zwischenfazit Potentiale prädiktiver EMS

In diesem Kapitel wurden ausgewählte Verfahren zur Prädiktion des zukünftigen Drehmoments vorgestellt. Dabei wurde gezeigt, dass hierfür besonders RNN geeignet sind und sich zusätzliche Verbesserungen durch die Verwendung von Kartendaten erzielen lassen. Darüber hinaus wurde eine prädiktive Online-ECMS vorgestellt, mit der entsprechende Prädiktionen zur Realisierung zusätzlicher Kraftstoffeinsparpotentiale genutzt werden können. Außerdem wurde eine alternative Methode für eine prädiktive Online-ECMS vorgestellt, mit der auch ohne explizite Prädiktion des Fahrgeschwindigkeitsprofils Einsparpotentiale möglich sind. Obgleich eine Verbesserung durch die Verwendung prädiktiver Informationen für ausgewählte Anwendungsfälle aufgezeigt werden konnte (z. B. bei sehr kleinen Batterien), muss im

Einzelfall geprüft werden, ob der Einsatz einer prädiktiven Online-ECMS sinnvoll ist. Im Hinblick auf die Nähe der nichtprädiktiven Online-ECMS zur global kraftstoffoptimalen Lösung und keinen Bestrebungen zum aktuellen Zeitpunkt hinsichtlich der Verwendung von Batterien mit nutzbaren Energieinhalten ≤ 100 Wh, werden die Untersuchungen zum Themenbereich *Prädiktive EMS* im Rahmen der vorliegenden Arbeit nicht weiter vertieft. So entfällt auch die Entwicklung einer zusammenhängenden Methodik, in der die Prädiktionsverfahren aus Kapitel 6.1 bzw. Kapitel 6.2 mit einer prädiktiven Online-ECMS gekoppelt werden und die Einflüsse der Prädiktionsungenauigkeiten auf die erzielten optimalen EMS näher untersucht wird. Es gilt außerdem kritisch festzuhalten, dass durch die Verwendung des *Alternativen Datensatzes* die Vergleichbarkeit der Ergebnisse eingeschränkt ist. Zwar konnten für den *Ansatz 1* aus Kapitel 6.3 weiterhin die zwölf Realfahrzyklen aus Abbildung 2.7 verwendet werden, welche die statistischen Merkmale der über 1 000 000 km Fahrdaten repräsentieren. Für *Ansatz 2* aus Kapitel 6.3 bzw. die vorangegangenen Analysen zur Prädiktion drehmomentrelevanter Größen (Kapitel 6.2) musste jedoch jeweils auf den *Alternativen Datensatz* zurückgegriffen werden. Grund hierfür war die Notwendigkeit von Ortsinformationen (GNSS-Daten) für eine Anreicherung der Fahrzyklen mit Kartendaten. Mit diesen angereicherten Fahrzyklen konnten schließlich die aufgezeigten Untersuchungen zu prädiktiven EMS durchgeführt werden. Hier wäre ein einheitlicher Datensatz für zukünftige Analysen besser, obgleich die Verarbeitung eines entsprechenden Datensatzes datenschutzrechtlich stets eine Herausforderung darstellt. Da in diesem Kapitel nur grundsätzliche Potenzialanalysen zu prädiktiven EMS angestellt wurden, hält der Autor die hierdurch auftretende Unschärfe insgesamt für vertretbar.

7 Zusammenfassung und Ausblick

In diesem Kapitel werden die wichtigsten Erkenntnisse der Arbeit zusammengefasst und es wird ein Ausblick gegeben.

7.1 Zusammenfassung

Im Rahmen der Arbeit wurden Untersuchungen zu Energiemangementstrategien (EMS) für hybridelektrische Fahrzeuge (48 V-System) durchgeführt, die sowohl die Systemauslegung, wie auch die spätere Implementierung umfassen. Für die Untersuchungen wurden reale Betriebsbedingungen, repräsentiert durch entsprechende Fahrzyklen, angenommen. Es wurden die Anwendbarkeit vorhandener Konzepte analysiert und geeignete Schnittstellen definiert. Ebenso wurde das Forschungsfeld durch neue, generisch einsetzbare Methoden ergänzt. Hierbei wurden auch prädiktive Ansätze entwickelt, sowie Einsatzmöglichkeiten des Maschinellen Lernens aufgezeigt. Folgende, in dieser Arbeit entwickelte Methodiken werden an dieser Stelle hervorgehoben:

- Eine Methodik zur Auslegung einer im realen Fahrbetrieb robusten, onlinefähigen EMS für 48 V-Systeme basierend auf dem Konzept einer SOC-abhängigen Online-ECMS. Diese ermöglicht eine Anwendbarkeit auf mehrere Topologien und stellt stets einen optimalen Betrieb von VKM und EM sicher.
- Eine Methodik um mittels Rekurrenter Neuronaler Netze (RNN) den zukünftigen Drehmomentbedarf zur Anwendung einer Modellprädiktiven Regelung (MPC) zu präzisieren. Dies umfasst auch eine generische Erweiterung um zusätzliche Informationen wie beispielsweise Kartendaten.

- Eine Methodik zur Realisierung einer prädiktiven Online-ECMS basierend auf Rekuperationspotentialen.
- Eine Methodik zur Realisierung einer prädiktiven Online-ECMS basierend auf Kartendaten.

Der Stand der Forschung zur Systemauslegung zeigte, dass sich viele Untersuchungen auf eine Optimierung des Kraftstoffverbrauchs beschränken. Weitere Optimierungsziele zur Berücksichtigung realer Betriebsbedingungen wie beispielsweise der Fahrkomfort (repräsentiert durch VKM-Starts), wurden bisher meist vernachlässigt. In diesem Kontext wurde auch der Mehrwert der Anwendung einer DP gegenüber einer Offline-ECMS in der Literatur bisher nicht eindeutig geklärt. In der vorliegenden Arbeit wurde gezeigt, dass die DP Energiemangementstrategien (EMS) bestimmt, die den aufgezeigten Zielkonflikt zwischen CO₂-Emissionen und Fahrkomfort (repräsentiert durch VKM-Starts) besser löst als die Offline-ECMS. Ein erheblicher Mehrwert durch die Anwendung der DP im Rahmen der Systemauslegung konnte außerdem dann gezeigt werden, wenn Komponenten wie die Batterie besonders kompakt dimensioniert werden sollen. Hieraus ließ sich schließen, dass Systempotentiale mittels der DP im Rahmen der Auslegung besser identifiziert werden. Ebenso wurde eine robuste, echtzeitfähige, nichtprädiktive Online-ECMS vorgestellt, die auch im realen Fahrbetrieb stets ein optimales Zusammenspiel von VKM und EM sicherstellt. Diese wurde mittels Realfahrzyklen ausgelegt und erfüllt den Anspruch an eine zuverlässige Einsetzbarkeit im realen Fahrbetrieb. Die Methodik wurde mit den Messdaten eines realen 48 V-Hybriden validiert. Darüber hinaus wurden allgemeine Handlungsempfehlungen für die bestehende EMS des Testfahrzeugs abgeleitet. Abschließend wurden die Potentiale prädiktiver EMS vorgestellt. Dabei wurde zunächst die Prädiktion drehmomentrelevanter Größen im Rahmen eines bewertenden Vergleichs von Markov Ketten (MC), vorwärtsrechnenden Neuronalen Netzen (FFNN) und Rekurrenten Neuronalen Netzen (RNN) diskutiert. Eine verbesserte Präzision durch die Verwendung von Neuronalen Netzen (ANN) gegenüber Markov Ketten (MC) konnte festgestellt werden (vgl. Deufel et al. [1] und [3]). Die Berücksichtigung von Kartendaten führte dabei zu einer zusätzlichen Erhöhung

der Prädiktionsgüte, insbesondere bei dynamischen Ereignissen im Fahrgeschwindigkeitsprofil. Anschließend wurden zwei Konzepte für eine prädiktive Online-ECMS vorgestellt, die jeweils eine Weiterentwicklung der zuvor vorgestellten, nichtprädiktiven Online-ECMS darstellen. Dabei wird der Basisalgorithmus im Falle des Vorhandenseins prädiktiver Informationen dynamisch erweitert. Mit beiden Konzepten konnten zusätzliche Einsparpotentiale gegenüber einer nichtprädiktiven Implementierung aufgezeigt werden (vgl. Deufel et al. [2] und [4]).

7.2 Ausblick

Wie eingangs erwähnt, enthält das Fahrzeugmodell einige Vereinfachungen, was für Relativbetrachtungen im Rahmen eines Vergleichs verschiedener Systeme oder EMS weitestgehend unkritisch ist. Wie sich bei der Validierung gezeigt hat, ist ein Abgleich der Absolutwerte mit realen Messdaten jedoch herausfordernd. Für Absolutbetrachtungen sollte der Detaillierungsgrad des Modells daher weiter gesteigert werden. Dies könnte beispielsweise durch die Berücksichtigung der Änderung des Reifenschlupfs und des dynamischen Radhalbmessers, oder durch die Berücksichtigung von Kurvenwiderständen erfolgen. Grundsätzlich kann die Realität in einem Simulationsmodell jedoch nur eingeschränkt abgebildet werden. Vor einem Serieneinsatz muss die Funktionalität der entwickelten Online-ECMS daher durch Applikationstests im Fahrzeug vollständig abgesichert werden (vgl. V-Modell). Können die simulativ aufgezeigten Potentiale bei der Umsetzung der nichtprädiktiven Online-ECMS im Fahrzeug bestätigt werden, wäre es - sofern entsprechend kleine Batterien verbaut werden - außerdem denkbar, die vorgestellten prädiktiven Ansätze zu einer gesamtheitlichen, echtzeitfähigen prädiktiven Online-ECMS weiterzuentwickeln. Für eine Implementierung in einem realen Fahrzeug muss für die Prädiktion des zukünftigen Fahrprofils mit den vorgestellten Algorithmen die Fahrzeuggeschwindigkeit approximiert werden, um die Karteninformationen aus dem Wegbereich in den Zeitbereich zu übertragen. Alternativ könnte in weiteren Untersuchungen anstelle des vorgegebenen Zeithorizonts auch direkt die Distanz verwendet werden. Bei

den vorgestellten Prädiktionsalgorithmen kann die Präzision der Vorhersagen außerdem durch eine Anreicherung mit zusätzlichen Informationen erhöht werden. Falls verfügbar, können Radar-, Lidar- und Kamera- oder Umgebungsdaten von C2C- und C2X-Kommunikation sowie Navigationssystemen herangezogen werden, um die Dynamiken noch besser vorherzusagen. Mittels parametrischen Methoden können zudem langfristige Vorhersagen getroffen werden, um ergänzende Informationen für die EMS bereitzustellen (vgl. Deufel et al. [1]).

Die DP ermöglicht zudem die Berücksichtigung weiterer Effekte im Rahmen der Systemauslegung, wie beispielsweise das thermische Verhalten der VKM und des KAT in Abhängigkeit der VKM-Laufzeit. Durch eine Kopplung des bestehenden Modells mit entsprechenden thermischen Modellen der jeweiligen Komponenten können so Änderungen im Wirkungsgrad oder die entstehenden Abgasemissionen abgebildet werden. Damit kann in den Lösungen des Optimierers das reale Betriebsverhalten der Komponenten besser berücksichtigt werden und so verschiedene Systeme besser miteinander verglichen werden.

Die aufgezeigten Optimierungsalgorithmen können auch auf Problemstellungen angewandt werden, die sich bei rein batteriebetriebenen Elektrofahrzeugen (BEV) stellen, da BEVs mit mehreren Elektromotoren auch eine EMS benötigen. Dies umfasst beispielsweise:

- Die Wahl der optimalen Drehmomentverteilung zwischen den EM.
- Die Abkuppelvorgänge der jeweiligen EM beim Verbau einer Kupplung (engl. *Disconnect*).
- Die Bestimmung der optimalen Schaltstrategie beim Verbau eines oder mehrerer Mehrganggetriebe.

Darüber hinaus sollte in weiterführenden Untersuchungen geprüft werden, ob Prädiktionsalgorithmen unter Verwendung von Methoden des Maschinellen Lernens auch das Energiemanagement von BEVs positiv beeinflussen. Grundsätzlich besteht eine generische Einsetzbarkeit der entwickelten Prädiktionsalgorithmen. Insbesondere Verbesserungen beim prädiktiven Batteriemanagement sind zu erwarten.

Literatur

- [Acc20] ACCURSO, F.; ZANELLI, A.; ROLANDO, L. und MILLO, F.: „Real Time Energy Management Control Strategies for an Electrically Supercharged Gasoline Hybrid Vehicle“. In: *SAE Technical Paper 2020-01-1009* (2020). DOI: [10.4271/2020-01-1009](https://doi.org/10.4271/2020-01-1009) (siehe S. 27, 37).
- [Adh10] ADHIKARI, S.; HALGAMUGE, S. K. und WATSON, H. C.: „An Online Power-Balancing Strategy for a Parallel Hybrid Electric Vehicle Assisted by an Integrated Starter Generator“. In: *IEEE Transactions on Vehicular Technology* 59.6 (2010), S. 2689–2699. DOI: [10.1109/TVT.2010.2051048](https://doi.org/10.1109/TVT.2010.2051048) (siehe S. 27, 37).
- [Agg18] AGGARWAL, C. C.: *Neural Networks and Deep Learning*. Cham: Springer International Publishing, 2018. DOI: [10.1007/978-3-319-94463-0](https://doi.org/10.1007/978-3-319-94463-0) (siehe S. 25, 46–50, 252).
- [Al 15] AL OMARI, B. H. und AL JAFARI, A.: „Roles of driver and vehicle characteristics in speed choice along rural highways“. In: *International Journal of Engineering Management and Economics* 5.3/4 (2015), S. 181. DOI: [10.1504/IJEME.2015.072551](https://doi.org/10.1504/IJEME.2015.072551) (siehe S. 42).
- [Alh16] ALHANOUTI, M.; GIEBLER, M.; BLANK, T. und GAUTERIN, F.: „New Electro-Thermal Battery Pack Model of an Electric Vehicle“. In: *Energies* 9.7 (2016), S. 563. DOI: [10.3390/en9070563](https://doi.org/10.3390/en9070563) (siehe S. 17).
- [Bac06] BACK, M.: „Prädiktive Antriebsregelung zum energieoptimalen Betrieb von Hybridfahrzeugen“. Dissertation. Karlsruhe: Universität Karlsruhe, 2006 (siehe S. 39, 43, 54, 55, 85).
- [Bal15] BALAZS, A.: „Optimierte Auslegung von Hybridantriebssträngen unter realen Fahrbedingungen“. Dissertation. Aachen:

- Rheinisch-Westfälische Technische Hochschule Aachen, 2015 (siehe S. 24).
- [Bau19] BAUER, K.-L.: „Echtzeit-Strategieplanung für vorausschauendes automatisiertes Fahren“. Dissertation. Karlsruhe: Karlsruher Institut für Technologie, 2019 (siehe S. 28, 32, 39, 54, 85).
- [Bel57] BELLMAN, R.: *Dynamic Programming*. Princeton, NJ, USA: Princeton University Press, 1957 (siehe S. 30, 32).
- [Bou17] BOUWMAN, K. R.; PHAM, T. H.; WILKINS, S. und HOFMAN, T.: „Predictive Energy Management Strategy Including Traffic Flow Data for Hybrid Electric Vehicles“. In: *IFAC-PapersOnLine* 50.1 (2017), S. 10046–10051. DOI: [10.1016/j.ifacol.2017.08.1775](https://doi.org/10.1016/j.ifacol.2017.08.1775) (siehe S. 53).
- [Bur09] BURG, H. und MOSER, A., Hrsg.: *Handbuch Verkehrsunfallrekonstruktion: Unfallaufnahme, Fahrdynamik, Simulation*. Wiesbaden: Vieweg + Teubner, 2009 (siehe S. 242).
- [Cao17] CAO, J. und XIONG, R.: „Reinforcement Learning-based Real-time Energy Management for Plug-in Hybrid Electric Vehicle with Hybrid Energy Storage System“. In: *Energy Procedia* 142 (2017), S. 1896–1901. DOI: [10.1016/j.egypro.2017.12.386](https://doi.org/10.1016/j.egypro.2017.12.386) (siehe S. 26).
- [Car20] CARDOSO, D. S.; FAEL, P. O. und ESPÍRITO-SANTO, A.: „A review of micro and mild hybrid systems“. In: *Energy Reports* 6 (2020), S. 385–390. DOI: [10.1016/j.egy.2019.08.077](https://doi.org/10.1016/j.egy.2019.08.077) (siehe S. 80).
- [Cha10] CHASSE, A.; SCIARRETTA, A. und CHAUVIN, J.: „Online optimal control of a parallel hybrid with costate adaptation rule“. In: *6th IFAC Symposium Advances in Automotive Control Munich, Germany, July 12-14* (2010), S. 99–104 (siehe S. 27, 53).
- [Cha11] CHASSE, A. und SCIARRETTA, A.: „Supervisory control of hybrid powertrains: An experimental benchmark of offline optimization and online energy management“. In: *Control Engineering Practice* 19.11 (2011), S. 1253–1265. DOI: [10.1016/j.conengprac.2011.04.008](https://doi.org/10.1016/j.conengprac.2011.04.008) (siehe S. 24, 27, 37).

- [Cha21] CHANDRA, R.; GOYAL, S. und GUPTA, R.: „Evaluation of Deep Learning Models for Multi-Step Ahead Time Series Prediction“. In: *IEEE Access* 9 (2021), S. 83105–83123. DOI: [10.1109/ACCESS.2021.3085085](https://doi.org/10.1109/ACCESS.2021.3085085) (siehe S. 44, 135).
- [Che18] CHEVALIER, G.: „LARNN: Linear Attention Recurrent Neural Network“. In: *CoRR* abs/1808.05578 (2018). DOI: [10.48550/arXiv.1808.05578](https://doi.org/10.48550/arXiv.1808.05578) (siehe S. 49).
- [Che20] CHEN, D.; KIM, Y. und STEFANOPOULOU, A. G.: „Predictive Equivalent Consumption Minimization Strategy With Segmented Traffic Information“. In: *IEEE Transactions on Vehicular Technology* 69.12 (2020), S. 14377–14390. DOI: [10.1109/TVT.2020.3034552](https://doi.org/10.1109/TVT.2020.3034552) (siehe S. 53).
- [Che21] CHEN, Z.; LIU, Y.; ZHANG, Y.; LEI, Z.; CHEN, Z. und LI, G.: „A neural network-based ECMS for optimized energy management of plug-in hybrid electric vehicles“. In: *Energy* (2021), S. 122727. DOI: [10.1016/j.energy.2021.122727](https://doi.org/10.1016/j.energy.2021.122727) (siehe S. 27).
- [Chu14] CHUNG, J.; GULCEHRE, C.; CHO, K. und BENGIO, Y.: „Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling“. In: *CoRR* abs/1412.3555 (2014). DOI: [10.48550/arXiv.1412.3555](https://doi.org/10.48550/arXiv.1412.3555) (siehe S. 50).
- [Di 14] DI CAIRANO, S.; BERNARDINI, D.; BEMPORAD, A. und KOLMANOVSKY, I. V.: „Stochastic MPC With Learning for Driver-Predictive Vehicle Control and its Application to HEV Energy Management“. In: *IEEE Transactions on Control Systems Technology* 22.3 (2014), S. 1018–1031. DOI: [10.1109/TCST.2013.2272179](https://doi.org/10.1109/TCST.2013.2272179) (siehe S. 54).
- [Dit06] DITTMAR, R. und PFEIFFER, B.-M.: „Modellbasierte prädiktive Regelung in der industriellen Praxis (Industrial Application of Model Predictive Control)“. In: *at - Automatisierungstechnik* 54.12 (2006), S. 590–601. DOI: [10.1524/auto.2006.54.12.590](https://doi.org/10.1524/auto.2006.54.12.590) (siehe S. 40).

- [Don20] DONG, P.; WU, S.; WANG, F.; WANG, Y.; XU, X.; WANG, S.; LIU, Y. und GUO, W.: „Energy management strategy based on velocity prediction for parallel plug-in hybrid electric bus“. In: *Proceedings of the 2020 4th CAA International Conference on Vehicular Control and Intelligence (CVCI), Hangzhou, China, December 18-20 (2020)*, S. 204–209. DOI: [10.1109/CVCI51460.2020.9338649](https://doi.org/10.1109/CVCI51460.2020.9338649) (siehe S. 27, 37).
- [Elb13] ELBERT, P.; EBBESEN, S. und GUZZELLA, L.: „Implementation of Dynamic Programming for n -Dimensional Optimal Control Problems With Final State Constraints“. In: *IEEE Transactions on Control Systems Technology* 21.3 (2013), S. 924–931. DOI: [10.1109/TCST.2012.2190935](https://doi.org/10.1109/TCST.2012.2190935) (siehe S. 26, 53, 70).
- [Elm90] ELMAN, J. L.: „Finding Structure in Time“. In: *Cognitive Science* 14 (1990), S. 179–211 (siehe S. 48).
- [Ena17] ENANG, W. und BANNISTER, C.: „Robust proportional ECMS control of a parallel hybrid electric vehicle“. In: *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering* 231.1 (2017), S. 99–119. DOI: [10.1177/0954407016659198](https://doi.org/10.1177/0954407016659198) (siehe S. 27, 53, 87).
- [Eng19] ENGBROKS, L.; KNAPPE, P.; GOERKE, D.; SCHMIEDLER, S.; GOEDECKE, T. und GERINGER, B.: „Energetic Costs of ICE Starts in (P)HEV - Experimental Evaluation and Its Influence on Optimization Based Energy Management Strategies“. In: *SAE Technical Paper 2019-24-0203* (2019). DOI: [10.4271/2019-24-0203](https://doi.org/10.4271/2019-24-0203) (siehe S. 54, 75).
- [Eur02] EUROPÄISCHE KOMMISSION: „Verordnung (EG) Nr. 1400/2002 vom 31. Juli 2002 über die Anwendung von Artikel 81 Absatz 3 des Vertrags auf Gruppen von vertikalen Vereinbarungen und aufeinander abgestimmten Verhaltensweisen im Kraftfahrzeugsektor“. In: *ABl. L 203* (2002) (siehe S. 14).
- [Fal23] FALKENA, W.: *xml2struct*. MATLAB Central File Exchange, 2023. URL: <https://www.mathworks.com/matlabcentral/fileexchange/28518-xml2struct>. Zugriff am 25. März 2023 (siehe S. 240).

- [Fes09] FESEFELDT, T. und MÜLLER, S.: „Optimization and Comparison of Quick and Hybrid Start“. In: *SAE Technical Paper 2009-01-1340* (2009). DOI: [10.4271/2009-01-1340](https://doi.org/10.4271/2009-01-1340) (siehe S. 75).
- [Fil23] FILIPPIDIS, I.: *OpenStreetMap Functions*. Github, 2023. URL: <https://github.com/johnyf/openstreetmap>. Zugriff am 25. März 2023 (siehe S. 240).
- [Fin02] FINDEISEN, R. und ALLGÖWER, F.: „An introduction to nonlinear model predictive control“. In: *21st Benelux Meeting on Systems and Control, Veldhoven, The Netherlands, March 19 – 21* (2002), S. 119–141 (siehe S. 40).
- [För20] FÖRSTER, D.; INDERKA, R. B. und GAUTERIN, F.: „Data-Driven Identification of Characteristic Real-Driving Cycles Based on k-Means Clustering and Mixed-Integer Optimization“. In: *IEEE Transactions on Vehicular Technology* 69.3 (2020), S. 2398–2410. DOI: [10.1109/TVT.2019.2963272](https://doi.org/10.1109/TVT.2019.2963272) (siehe S. 131, 133, 245, 249).
- [För21] FÖRSTER, D.; DECKER, L.; DOPPELBAUER, M. und GAUTERIN, F.: „Analysis of CO2 reduction potentials and component load collectives of 48 V-hybrids under real-driving conditions“. In: *Automotive and Engine Technology* 6.1-2 (2021), S. 45–62. DOI: [10.1007/s41104-021-00076-3](https://doi.org/10.1007/s41104-021-00076-3) (siehe S. 9, 11, 14, 20, 21, 54, 56, 57, 61, 81, 111).
- [För24] FÖRSTER, D.: „Systemauslegung Autarker Hybridantriebe Unter Berücksichtigung Kundenspezifischer Randbedingungen“. Dissertation. Karlsruhe: Karlsruher Institut für Technologie, 2024 (siehe S. 1, 6, 7, 13, 14, 19, 22, 37, 57, 60–62, 64, 65, 78, 81, 89, 91, 99, 118, 129, 223).
- [Fu17] FU, Z.; LIU, X.; LI, H. und LI, Z.: „Equivalent Consumption Minimization Strategy“. In: *IEEE Chinese Automation Congress (CAC), Jinan, China, October 20-22* (2017), S. 4215–4219. DOI: [10.1109/CAC.2017.8243519](https://doi.org/10.1109/CAC.2017.8243519) (siehe S. 27, 53).

- [Gan18] GANGOPADHYAY, T.; TAN, S. Y.; HUANG, G. und SARKAR, S.: „Temporal Attention and Stacked LSTMs for Multivariate Time Series Prediction“. In: *Workshop on Modeling and Decision-Making in the Spatiotemporal Domain, 32nd Conference on Neural Information Processing Systems (NIPS 2018), Montreal, Canada, December 3-8 (2018)* (siehe S. 135).
- [Gao17] GAO, A.; DENG, X.; ZHANG, M. und FU, Z.: „Design and Validation of Real-Time Optimal Control with ECMS to Minimize Energy Consumption for Parallel Hybrid Electric Vehicles“. In: *Mathematical Problems in Engineering* (2017), S. 1–13. DOI: [10.1155/2017/3095347](https://doi.org/10.1155/2017/3095347) (siehe S. 27, 53).
- [Gau02] GAUSEMEIER, J. und MOEHRINGER, S.: „VDI 2206- A New Guideline for the Design of Mechatronic Systems“. In: *IFAC Proceedings Volumes 35.2, Berkeley, CA, USA, December 9-11 (2002)*, S. 785–790. DOI: [10.1016/S1474-6670\(17\)34035-1](https://doi.org/10.1016/S1474-6670(17)34035-1) (siehe S. 1, 2).
- [Geo23] GEOFABRIK: *OpenStreetMap Data Extracts*. Geofabrik GmbH, 2023. URL: <https://download.geofabrik.de/>. Zugriff am 25. März 2023 (siehe S. 240).
- [Ger00] GERS, F. und SCHMIDHUBER, J.: „Recurrent Nets that Time and Count“. In: *Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks. IJCNN 2000. Neural Computing: New Challenges and Perspectives for the New Millennium, Como, Italy, July 27 (2000)*, S. 189–194. DOI: [10.1109/IJCNN.2000.861302](https://doi.org/10.1109/IJCNN.2000.861302) (siehe S. 50).
- [Goo16] GOODFELLOW, I.; BENGIO, Y. und COURVILLE, A.: *Deep Learning*. o.O.: MIT Press, 2016. URL: <https://www.deeplearningbook.org/>. Zugriff am 25. März 2023 (siehe S. 48).
- [Gör16] GÖRKE, D.: „Untersuchungen zur kraftstoffoptimalen Betriebsweise von Parallelhybridfahrzeugen und darauf basierende Auslegung regelbasierter Betriebsstrategien“. Dissertation. Stuttgart: Universität Stuttgart, 2016 (siehe S. 9, 10, 34, 35, 37, 54, 60, 75, 87, 143, 146, 209).

- [Gra13] GRAVES, A.; MOHAMED, A.-R. und HINTON, G.: „Speech Recognition with Deep Recurrent Neural Networks“. In: *2013 IEEE International Conference on Acoustics, Speech and Signal Processing, Vancouver, BC, Canada, May 26-31* (2013), S. 6645–6649. DOI: [10.1109/ICASSP.2013.6638947](https://doi.org/10.1109/ICASSP.2013.6638947) (siehe S. 49, 252).
- [Gra14] GRAVES, A.: „Generating Sequences With Recurrent Neural Networks“. In: *CoRR abs/1308.0850* (2014). DOI: [10.48550/arXiv.1308.0850](https://doi.org/10.48550/arXiv.1308.0850) (siehe S. 49, 252).
- [Gre17] GREFF, K.; SRIVASTAVA, R. K.; KOUTNIK, J.; STEUNEBRINK, B. R. und SCHMIDHUBER, J.: „LSTM: A Search Space Odyssey“. In: *IEEE transactions on neural networks and learning systems* 28.10 (2017), S. 2222–2232. DOI: [10.1109/TNNLS.2016.2582924](https://doi.org/10.1109/TNNLS.2016.2582924) (siehe S. 50).
- [Gri19] GRIEFNOW, P.; ANDERT, J.; XIA, F.; KLEIN, S.; STOFFEL, P.; ENGELS, M. und JOLOVIC, D.: „Real-Time Modeling of a 48V P0 Mild Hybrid Vehicle with Electric Compressor for Model Predictive Control“. In: *SAE Technical Paper 2019-01-0350* (2019). DOI: [10.4271/2019-01-0350](https://doi.org/10.4271/2019-01-0350) (siehe S. 80).
- [Gri21] GRIEFNOW, P.: „Nichtlineare modellprädiktive Regelung von Mild-Hybridantrieben mit elektrischer Zusatzaufladung“. Dissertation. Aachen: Rheinisch-Westfälische Technische Hochschule Aachen, 2021 (siehe S. 54, 55).
- [Gu06] GU, B. und RIZZONI, G.: „An Adaptive Algorithm for Hybrid Electric Vehicle Energy Management Based on Driving Pattern Recognition“. In: *Proceedings of IMECE2006, Chicago, IL, USA, November 5–10* (2006). DOI: [10.1115/IMECE2006-13951](https://doi.org/10.1115/IMECE2006-13951) (siehe S. 27).
- [Guo20] GUO, X.; LIU, T.; TANG, B.; TANG, X.; ZHANG, J.; TAN, W. und JIN, S.: „Transfer Deep Reinforcement Learning-Enabled Energy Management Strategy for Hybrid Tracked Vehicle“. In: *IEEE Access* 8 (2020), S. 165837–165848. DOI: [10.1109/ACCESS.2020.3022944](https://doi.org/10.1109/ACCESS.2020.3022944) (siehe S. 26).

- [Guz13] GUZZELLA, L. und SCIARRETTA, A.: *Vehicle propulsion systems: Introduction to modeling and optimization*. Berlin, Heidelberg: Springer, 2013. DOI: [10.1007/978-3-642-35913-2](https://doi.org/10.1007/978-3-642-35913-2) (siehe S. 12).
- [Han17] HAN, J.; KUM, D. und PARK, Y.: „Synthesis of Predictive Equivalent Consumption Minimization Strategy for Hybrid Electric Vehicles Based on Closed-Form Solution of Optimal Equivalence Factor“. In: *IEEE Transactions on Vehicular Technology* 66.7 (2017), S. 5604–5616. DOI: [10.1109/TVT.2017.2660764](https://doi.org/10.1109/TVT.2017.2660764) (siehe S. 53).
- [Hel15] HELBING, M.; UEBEL, S.; TEMPELHAHN, C. und BAEKER, B.: „Bewertender Überblick von Methoden zur Antriebsstrangsteuerung in Hybrid und Elektrofahrzeugen“. In: *ATZechnik* 10 (2015), S. 66–71. DOI: [10.1007/s35658-015-0573-2](https://doi.org/10.1007/s35658-015-0573-2) (siehe S. 36).
- [Hel20] HELLWIG, M. und RITSCHER, W.: „The Predictability of Driving in Typical Traffic Conditions“. In: *21st International Conference on Research and Education in Mechatronics (REM), Cracow, Poland, December 09-11 (2020)*. DOI: [10.1109/REM49740.2020.9313900](https://doi.org/10.1109/REM49740.2020.9313900) (siehe S. 43).
- [Hoc97] HOCHREITER, S. und SCHMIDHUBER, J.: „Long Short-Term Memory“. In: *Neural Computation* 9(8) (1997), S. 1735–1780. DOI: [10.1162/neco.1997.9.8.1735](https://doi.org/10.1162/neco.1997.9.8.1735) (siehe S. 48).
- [Hol23] HOLLSTEIN, R.: *Optimierungsmethoden - Einführung in die klassischen, naturanalogen und neuronalen Optimierungen*. Wiesbaden: Springer Fachmedien Wiesbaden, 2023. DOI: [10.1007/978-3-658-39855-2](https://doi.org/10.1007/978-3-658-39855-2) (siehe S. 48).
- [Hu18] HU, Y.; LI, W.; XU, K.; ZAHID, T.; QIN, F. und LI, C.: „Energy Management Strategy for a Hybrid Electric Vehicle Based on Deep Reinforcement Learning“. In: *Applied Sciences* 8.2 (2018), S. 187. DOI: [10.3390/app8020187](https://doi.org/10.3390/app8020187) (siehe S. 24, 26).
- [Hua17] HUANG, Y.; WANG, H.; KHAJEPOUR, A.; HE, H. und JI, J.: „Model predictive control power management strategies for HEVs: A review“. In: *Journal of Power Sources* 341 (2017), S. 91–106. DOI: [10.1016/j.jpowsour.2016.11.106](https://doi.org/10.1016/j.jpowsour.2016.11.106) (siehe S. 28, 41, 54).

- [Jia17] JIANG, Q.; OSSART, F. und MARCHAND, C.: „Comparative Study of Real-Time HEV Energy Management Strategies“. In: *IEEE Transactions on Vehicular Technology* 66.12 (2017), S. 10875–10888. DOI: [10.1109/TVT.2017.2727069](https://doi.org/10.1109/TVT.2017.2727069) (siehe S. 24).
- [Jia18] JIANG, L. und HU, G.: „Day-Ahead Price Forecasting for Electricity Market using Long-Short Term Memory Recurrent Neural Network“. In: *15th International Conference on Control, Automation, Robotics and Vision (ICARCV), Singapore, November 18-21* (2018). DOI: [10.1109/ICARCV.2018.8581235](https://doi.org/10.1109/ICARCV.2018.8581235) (siehe S. 49, 252).
- [Joh08] JOHANNESSON, L. und EGARDT, B.: „Approximate Dynamic Programming Applied to Parallel Hybrid Powertrains“. In: *Proceedings of the 17th World Congress, The International Federation of Automatic Control, Seoul, Korea, July 8-11* (2008). DOI: [10.3182/20080706-5-KR-1001.00573](https://doi.org/10.3182/20080706-5-KR-1001.00573) (siehe S. 127).
- [Jos14] JOSEVSKI, M. und ABEL, D.: „Energy Management of Parallel Hybrid Electric Vehicles based on Stochastic Model Predictive Control“. In: *IFAC Proceedings Volume 47, Issue 3, Cape Town, South Africa. August 24-29* (2014), S. 2132–2137. DOI: [10.3182/20140824-6-ZA-1003.01329](https://doi.org/10.3182/20140824-6-ZA-1003.01329) (siehe S. 28).
- [Još18] JOŠEVSKI, M.: „Predictive Energy Management of Hybrid Electric Vehicles with Uncertain Torque Demand Forecast for On-Road Operation“. Dissertation. Aachen: Rheinisch-Westfälische Technische Hochschule Aachen, 2018 (siehe S. 40, 41, 50, 54, 143).
- [Joz15] JOZEFOWICZ, R.; ZAREMBA, W. und SUTSKEVER, I.: „An Empirical Exploration of Recurrent Network Architectures“. In: *Proceedings of the 32nd International Conference on Machine Learning. JMLR: W&CP volume 37, Lille, France, July 6-11* (2015). URL: <https://api.semanticscholar.org/CorpusID:9668607> (siehe S. 50).
- [Kaz17] KAZEMI, H.; FALLAH, Y. P.; NIX, A. und WAYNE, S.: „Predictive AECMS by Utilization of Intelligent Transportation Systems for

- Hybrid Electric Vehicle Powertrain Control“. In: *IEEE Transactions on Intelligent Vehicles* 2.2 (2017), S. 75–84. DOI: [10.1109/TIV.2017.2716839](https://doi.org/10.1109/TIV.2017.2716839) (siehe S. 53).
- [Kes08] KESSELS, J.T.B.A.; KOOT, M.W.T.; BOSCH, P.P.J. van den und KOK, D. B.: „Online Energy Management for Hybrid Electric Vehicles“. In: *IEEE Transactions on Vehicular Technology* 57.6 (2008), S. 3428–3440. DOI: [10.1109/TVT.2008.919988](https://doi.org/10.1109/TVT.2008.919988) (siehe S. 27, 53).
- [Kim09] KIM, N.; LEE, D.; CHA, S.-W. und PENG, H.: „Optimal Control of a Plug-In Hybrid Electric Vehicle (PHEV) Based on Driving Patterns“. In: *EVS24 International Battery, Hybrid and Fuel Cell Electric Vehicle Symposium, Stavanger, Norway, May 13-16* (2009) (siehe S. 60).
- [Kim11] KIM, N.; CHA, S. und PENG, H.: „Optimal Control of Hybrid Electric Vehicles Based on Pontryagin’s Minimum Principle“. In: *IEEE Transactions on Control Systems Technology* 19.5 (2011), S. 1279–1287. DOI: [10.1109/TCST.2010.2061232](https://doi.org/10.1109/TCST.2010.2061232) (siehe S. 27, 36, 53, 66, 72).
- [Kim12] KIM, N. und ROUSSEAU, A.: „Sufficient conditions of optimal control based on Pontryagin’s minimum principle for use in hybrid electric vehicles“. In: *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering* 226.9 (2012), S. 1160–1170. DOI: [10.1177/0954407012438304](https://doi.org/10.1177/0954407012438304) (siehe S. 27, 36, 53, 60).
- [Kir70] KIRK, D.E.: *Optimal Control Theory. An Introduction*. Englewood Cliffs, NJ: Prentice-Hall, 1970 (siehe S. 35, 209).
- [Kon17] KONG, Z.; ZOU, Y. und LIU, T.: „Implementation of real-time energy management strategy based on reinforcement learning for hybrid electric vehicles and simulation validation“. In: *PloS one* 12.7 (2017). DOI: [10.1371/journal.pone.0180491](https://doi.org/10.1371/journal.pone.0180491) (siehe S. 26).
- [Kur15] KURAL, E. und GÜVENC, B.: „Predictive-Equivalent Consumption Minimization Strategy for Energy Management of A Parallel Hybrid Vehicle for Optimal Recuperation“. In: *Journal of Polytechnic*, 18 (3) (2015), S. 113–124 (siehe S. 27, 53).

- [Lar20] LARAKI, M.; DE NUNZIO, G. und THIBAUT, L.: „Vehicle speed trajectory estimation using road traffic and infrastructure information“. In: *2020 IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC), Rhodes, Greece, September 20-23* (2020), S. 1–7. DOI: [10.1109/ITSC45102.2020.9294337](https://doi.org/10.1109/ITSC45102.2020.9294337) (siehe S. 43).
- [LeC15] LECUN, Y.; BENGIO, Y. und HINTON, G.: „Deep learning“. In: *Nature* 521.7553 (2015), S. 436–444. DOI: [10.1038/nature14539](https://doi.org/10.1038/nature14539) (siehe S. 47).
- [Lef14] LEFEVRE, S.; SUN, C.; BAJCSY, R. und LAUGIER, C.: „Comparison of parametric and non-parametric approaches for vehicle speed prediction“. In: *2014 American Control Conference, Portland, OR, USA, June 4-6* (2014), S. 3494–3499. DOI: [10.1109/ACC.2014.6858871](https://doi.org/10.1109/ACC.2014.6858871) (siehe S. 41, 42).
- [Li14] LI, L.; HUANG, H.; LIAN, J.; YAO, B.; ZHOU, Y.; CHANG, J. und ZHENG, N.: „Research of Ant Colony Optimized Adaptive Control Strategy for Hybrid Electric Vehicle“. In: *Mathematical Problems in Engineering* (2014), S. 1–10. DOI: [10.1155/2014/239130](https://doi.org/10.1155/2014/239130) (siehe S. 27).
- [Li16] LI, L.; YOU, S.; YANG, C.; YAN, B.; SONG, J. und CHEN, Z.: „Driving-behavior-aware stochastic model predictive control for plug-in hybrid electric buses“. In: *Applied Energy* 162 (2016), S. 868–879. DOI: [10.1016/j.apenergy.2015.10.152](https://doi.org/10.1016/j.apenergy.2015.10.152) (siehe S. 29, 54).
- [Li17] LI, Y.; HE, H.; PENG, J. und ZHANG, H.: „Power Management for a Plug-in Hybrid Electric Vehicle Based on Reinforcement Learning with Continuous State and Action Spaces“. In: *Energy Procedia* 142.3 (2017), S. 2270–2275. DOI: [10.1016/j.egypro.2017.12.629](https://doi.org/10.1016/j.egypro.2017.12.629) (siehe S. 26, 48, 252).
- [Lin21] LIN, X.; WANG, Z. und WU, J.: „Energy management strategy based on velocity prediction using back propagation neural network for a plug-in fuel cell electric vehicle“. In: *International Journal of Energy Research* 45.2 (2021), S. 2629–2643. DOI: [10.1002/er.5956](https://doi.org/10.1002/er.5956) (siehe S. 54).

- [Liu14] LIU, T.; ZOU, Y.; LIU, D.-X. und SUN, F.-C.: „Real-time control for a parallel hybrid electric vehicle based on Pontryagin’s Minimum Principle“. In: *IEEE Conference and Expo Transportation Electrification Asia-Pacific (ITEC Asia-Pacific)*, Beijing, China, August 31 - September 3 (2014). DOI: [10.1109/ITEC-AP.2014.6941257](https://doi.org/10.1109/ITEC-AP.2014.6941257) (siehe S. 53).
- [Liu18] LIU, H.; LI, X.; WANG, W.; HAN, L. und XIANG, C.: „Markov velocity predictor and radial basis function neural network-based real-time energy management strategy for plug-in hybrid electric vehicles“. In: *Energy* 152 (2018), S. 427–444. DOI: [10.1016/j.energy.2018.03.148](https://doi.org/10.1016/j.energy.2018.03.148) (siehe S. 54).
- [Liu20] LIU, Y.; CANOVA, M. und WANG, Y.-Y.: „Distributed Energy and Thermal Management of a 48-V Diesel Mild Hybrid Electric Vehicle With Electrically Heated Catalyst“. In: *IEEE Transactions on Control Systems Technology* 28.5 (2020), S. 1878–1891. DOI: [10.1109/TCST.2020.2997868](https://doi.org/10.1109/TCST.2020.2997868) (siehe S. 80).
- [Luu00] LUUS, R.: *Iterative Dynamic Programming*. New York: Chapman and Hall/CRC, 2000. DOI: [10.1201/9780429123641](https://doi.org/10.1201/9780429123641) (siehe S. 32).
- [Mat23] MATHWORKS: *Reinforcement Learning Agents*. MathWorks, 2023. URL: <https://de.mathworks.com/help/reinforcement-learning/ug/create-agents-for-reinforcement-learning.html>. Zugriff am 25. März 2023 (siehe S. 25).
- [May19] MAYER, A.; GLETTER, C.; NELLES, O.; KALLO, J. und WINSEL, T.: „Two-Dimensional ECMS for System Analysis of Hybrid Concepts featuring Two Electric Traction Motors“. In: *2019 International Symposium on Systems Engineering (ISSE)*, Edinburgh, UK, October 1-3 (2019). DOI: [10.1109/ISSE46696.2019.8984506](https://doi.org/10.1109/ISSE46696.2019.8984506) (siehe S. 27, 53).
- [Mig23] MIGURSKI, M.: *Osmosis*. Github, 2023. URL: <https://github.com/openstreetmap/osmosis/releases/tag/0.48.3>. Zugriff am 25. März 2023 (siehe S. 240).

- [Mus05] MUSARDO, C.; RIZZONI, G. und STACCIA, B.: „A-ECMS: An Adaptive Algorithm for Hybrid Electric Vehicle Energy Management“. In: *44th IEEE Conference on Decision and Control and European Control Conference ECC 2005, Seville, Spain, December 12-15 (2005)*. DOI: [10.1109/CDC.2005.1582424](https://doi.org/10.1109/CDC.2005.1582424) (siehe S. 27, 53).
- [Now17] NOWAK, J.; TASPINAR, A. und SCHERER, R.: „LSTM Recurrent Neural Networks for Short Text and Sentiment Classification“. In: *Artificial Intelligence and Soft Computing, ICAISC 2017, Zakopane, Poland, June 11-15 (2017)*, S. 553–562. DOI: [10.1007/978-3-319-59060-8_50](https://doi.org/10.1007/978-3-319-59060-8_50) (siehe S. 50).
- [Nüe14] NÜESCH, T.: „Energy Management of Hybrid Electric Vehicles“. Dissertation. Zürich: Eidgenössische Technische Hochschule Zürich, 2014 (siehe S. 54, 75).
- [Obe15] OBERFELL, R.: „Stochastische Simulation von Energieflüssen im Nutzfahrzeug“. Dissertation. Karlsruhe: Karlsruher Institut für Technologie, 2015 (siehe S. 12).
- [Ono10] ONORI, S.; SERRAO, L. und RIZZONI, G.: „Adaptive Equivalent Consumption Minimization Strategy for Hybrid Electric Vehicles“. In: *Proceedings of the ASME 2010 Dynamic Systems and Control Conference, Cambridge, MA, USA, September 12–15 (2010)*, S. 499–505. DOI: doi.org/10.1115/DSCC2010-4211 (siehe S. 27, 53).
- [Ono11] ONORI, S. und SERRAO, L.: „On Adaptive-ECMS strategies for hybrid electric vehicles“. In: *Les Rencontres Scientifiques d'IFP Energies nouvelles – International Scientific Conference on hybrid and electric vehicles – RHEVE 2011, Rueil-Malmaison, France, December 6-7 (2011)* (siehe S. 27, 53, 94).
- [Ono16] ONORI, S.; SERRAO, L. und RIZZONI, G.: *Hybrid Electric Vehicles*. London: Springer London, 2016. DOI: [10.1007/978-1-4471-6781-5](https://doi.org/10.1007/978-1-4471-6781-5) (siehe S. 12, 18, 24, 29–36, 59, 60, 143, 146, 209).

- [Oud18] OUDDAH, N.; ADOUANE, L. und ABDRAKHMANOV, R.: „From Off-line to Adaptive Online Energy Management Strategy of Hybrid Vehicle Using Pontryagin’s Minimum Principle“. In: *International Journal of Automotive Technology*, Vol. 19, No. 3 (2018), S. 571–584. DOI: [10.1007/s12239-018-0054-8](https://doi.org/10.1007/s12239-018-0054-8) (siehe S. 27, 53).
- [Pag02] PAGANELLI, G.; DELPRAT, S.; GUERRA, T. M.; RIMAU, J. und SANTIN, J. J.: „Equivalent consumption minimization strategy for parallel hybrid powertrains“. In: *IEEE 55th Vehicular Technology Conference, Birmingham, AL, USA, May 6-9 (2002)*, S. 2076–2081. DOI: [10.1109/VTC.2002.1002989](https://doi.org/10.1109/VTC.2002.1002989) (siehe S. 27, 36).
- [Par22] PARDHI, S.; EL BAGHDADI, M.; HULSEBOS, O. und HEGAZY, O.: „Optimal Powertrain Sizing of Series Hybrid Coach Running on Diesel and HVO for Lifetime Carbon Footprint and Total Cost Minimisation“. In: *Energies* 15.19 (2022). DOI: [10.3390/en15196974](https://doi.org/10.3390/en15196974) (siehe S. 27, 37).
- [Qi22] QI, C.; SONG, C.; XIAO, F. und SONG, S.: „Generalization ability of hybrid electric vehicle energy management strategy based on reinforcement learning method“. In: *Energy* 250.3 (2022). DOI: [10.1016/j.energy.2022.123826](https://doi.org/10.1016/j.energy.2022.123826) (siehe S. 24).
- [Qin17] QIN, F.; XU, G.; HU, Y.; XU, K. und LI, W.: „Stochastic Optimal Control of Parallel Hybrid Electric Vehicles“. In: *Energies* 10.2 (2017). DOI: [10.3390/en10020214](https://doi.org/10.3390/en10020214) (siehe S. 29, 54).
- [Qui99] QUIMBY, A.; MAYCOCK, G.; PALMER, C. und BUTTRESS, S.: „The factors that influence a driver’s choice of speed – a questionnaire study“. In: *Transport Research Laboratory - TRL REPORT 325* (1999). URL: <https://trl.co.uk/uploads/trl/documents/TRL325.pdf>. Zugriff am 25. März 2023 (siehe S. 42, 43).
- [Rab89] RABINER, L. R.: „A tutorial on hidden Markov models and selected applications in speech recognition“. In: *Proceedings of the IEEE*, Vol. 77, No. 2, February (1989), S. 257–286. DOI: [10.1109/5.18626](https://doi.org/10.1109/5.18626) (siehe S. 45, 46).

- [Rez15] REZAEI, A. und BURL, J. B.: „Prediction of Vehicle Velocity for Model Predictive Control“. In: *IFAC-PapersOnLine* 48.15 (2015), S. 257–262. DOI: [10.1016/j.ifacol.2015.10.037](https://doi.org/10.1016/j.ifacol.2015.10.037) (siehe S. 41, 43).
- [Riz15] RIZZONI, G. und ONORI, S.: „Energy Management of Hybrid Electric Vehicles: 15 years of development at the Ohio State University“. In: *Oil & Gas Science and Technology – Revue d'IFP Energies nouvelles* 70.1 (2015), S. 41–54. DOI: [10.2516/ogst/2014006](https://doi.org/10.2516/ogst/2014006) (siehe S. 24).
- [Sag05] SAGBERG, F.: „Factors influencing driving speed“. In: *TOI report* 765/2005 (2005). URL: <https://www.toi.no/publications/factors-influencing-driving-speed-article17837-29.html>. Zugriff am 25. März 2023 (siehe S. 43).
- [Sal07] SALMASI, F. R.: „Control Strategies for Hybrid Electric Vehicles: Evolution, Classification, Comparison, and Future Trends“. In: *IEEE Transactions on Vehicular Technology* 56.5 (2007), S. 2393–2404. DOI: [10.1109/TVT.2007.899933](https://doi.org/10.1109/TVT.2007.899933) (siehe S. 24).
- [Sal13] SALCHER, T.: „Optimierte Betriebsstrategie hybrider Antriebssysteme für den Serieneinsatz“. Dissertation. München: Technische Universität München, 2013 (siehe S. 54, 75).
- [Sch22] SCHMID, R.: „Optimierungsbasiertes vorausschauendes Energiemanagement von Plug-in-Hybridfahrzeugen“. Dissertation. Kaiserslautern: Technische Universität Kaiserslautern, 2022 (siehe S. 36, 54, 55).
- [Sci14] SCIARRETTA, A. u. a.: „A control benchmark on the energy management of a plug-in hybrid electric vehicle“. In: *Control Engineering Practice* 29.11 (2014), S. 287–298. DOI: [10.1016/j.conengprac.2013.11.020](https://doi.org/10.1016/j.conengprac.2013.11.020) (siehe S. 27, 37).
- [Ser09a] SERRAO, L.: „A Comparative Analysis Of Energy Management Strategies For Hybrid Electric Vehicles“. Dissertation. Ohio, USA: The Ohio State University, 2009 (siehe S. 24).

- [Ser09b] SERRAO, L.; ONORI, S. und RIZZONI, G.: „ECMS as a realization of Pontryagin’s minimum principle for HEV control“. In: *IEEE American Control Conference, St. Louis, MO, USA, June 10-12* (2009), S. 3964–3969. DOI: [10.1109/ACC.2009.5160628](https://doi.org/10.1109/ACC.2009.5160628) (siehe S. 27, 53).
- [Sil16a] SILVAS, E.; HEREIJGERS, K.; PENG, H.; HOFMAN, T. und STEINBUCH, M.: „Synthesis of Realistic Driving Cycles With High Accuracy and Computational Speed, Including Slope Information“. In: *IEEE Transactions on Vehicular Technology* 65.6 (2016), S. 4118–4128. DOI: [10.1109/TVT.2016.2546338](https://doi.org/10.1109/TVT.2016.2546338) (siehe S. 56, 133, 249).
- [Sil16b] SILVAS, E.; HOFMAN, T.; MURGOVSKI, N.; ETMAN, P. und STEINBUCH, M.: „Review of Optimization Strategies for System-Level Design in Hybrid Electric Vehicles“. In: *IEEE Transactions on Vehicular Technology* (2016), S. 57–70. DOI: [10.1109/TVT.2016.2547897](https://doi.org/10.1109/TVT.2016.2547897) (siehe S. 1, 10, 24).
- [Sil22] SILVA, D. C. D.; KEFSI, L. und SCIARRETTA, A.: „An analytical model to optimize the powertrain sizing of Fuel Cell Hybrid Electric Vehicles“. In: *IEEE Vehicle Power and Propulsion Conference (VPPC), Merced, CA, USA, November 1-4* (2022), S. 1–8. DOI: [10.1109/VPPC55846.2022.10003436](https://doi.org/10.1109/VPPC55846.2022.10003436) (siehe S. 27, 37).
- [Siv12] SIVERTSSON, M.: „Adaptive Control Using Map-Based ECMS for a PHEV“. In: *IFAC Proceedings Volumes, Volume 45, Issue 30, Rueil-Malmaison, France, October 23-25* (2012), S. 357–362. DOI: [10.3182/20121023-3-FR-4025.00074](https://doi.org/10.3182/20121023-3-FR-4025.00074) (siehe S. 27, 53).
- [Sun08] SUNDSTRÖM, O.; GUZZELLA, L. und SOLTIC, P.: „Optimal Hybridization in Two Parallel Hybrid Electric Vehicles using Dynamic Programming“. In: *Proceedings of the 17th World Congress The International Federation of Automatic Control, Seoul, Korea, July 6-11* (2008), S. 4642–4647 (siehe S. 26, 53).
- [Sun09] SUNDSTROM, O. und GUZZELLA, L.: „A generic dynamic programming Matlab function“. In: *18th IEEE International Conference on Control Applications, St. Petersburg, Russia, July 8-10*

- (2009), S. 1625–1630. DOI: [10.1109/CCA.2009.5281131](https://doi.org/10.1109/CCA.2009.5281131) (siehe S. 6, 7, 26, 29–32, 53, 62, 69, 70, 216).
- [Sun10] SUNDSTRÖM, O.; AMBÜHL, D. und GUZZELLA, L.: „On Implementation of Dynamic Programming for Optimal Control Problems with Final State Constraints“. In: *Oil & Gas Science and Technology – Revue de l’Institut Français du Pétrole* 65.1 (2010), S. 91–102. DOI: [10.2516/ogst/2009020](https://doi.org/10.2516/ogst/2009020) (siehe S. 26, 53).
- [Sun14] SUN, C.; HU, X.; MOURA, S. J. und SUN, F.: „Comparison of Velocity Forecasting Strategies for Predictive Control in HEVs“. In: *Proceedings of the ASME 2014 Dynamic Systems and Control Conference, San Antonio, TX, USA, October 22–24* (2014). DOI: [10.1115/DSCC2014-6031](https://doi.org/10.1115/DSCC2014-6031) (siehe S. 29, 54).
- [Sun15] SUN, C.; HU, X.; MOURA, S. J. und SUN, F.: „Velocity Predictors for Predictive Energy Management in Hybrid Electric Vehicles“. In: *IEEE Transactions on Control Systems Technology* 23.3 (2015), S. 1197–1204. DOI: [10.1109/TCST.2014.2359176](https://doi.org/10.1109/TCST.2014.2359176) (siehe S. 54).
- [Sun17] SUN, C.; SUN, F. und HE, H.: „Investigating adaptive-ECMS with velocity forecast ability for hybrid electric vehicles“. In: *Applied Energy* 185 (2017), S. 1644–1653. DOI: [10.1016/j.apenergy.2016.02.026](https://doi.org/10.1016/j.apenergy.2016.02.026) (siehe S. 54).
- [Sut14] SUTSKEVER, I.; VINYALS, O. und LE, Q. V.: „Sequence to Sequence Learning with Neural Networks“. In: *CoRR abs/1409.3215* (2014). DOI: [10.48550/arXiv.1409.3215](https://doi.org/10.48550/arXiv.1409.3215) (siehe S. 135).
- [Sut15] SUTTON, R. S. und BARTO, A. G.: *Reinforcement Learning - An Introduction*. o.O.: MIT Press, 2015. URL: <https://web.stanford.edu/class/psych209/Readings/SuttonBartoIPRLBook2ndEd.pdf>. Zugriff am 25. März 2023 (siehe S. 25).
- [Thi13] THIBAUT, L. und LEROY, T.: „Optimal Online Energy Management for Diesel HEV: Robustness to Real Driving Conditions“. In: *SAE Technical Paper 2013-01-1471* (2013). DOI: [10.4271/2013-01-1471](https://doi.org/10.4271/2013-01-1471) (siehe S. 27, 37).

- [Tra20] TRAN, D.-D.; VAFAEIPOUR, M.; EL BAGHDADI, M.; BARRERO, R.; VAN MIERLO, J. und HEGAZY, O.: „Thorough state-of-the-art analysis of electric and hybrid vehicle powertrains: Topologies and integrated energy management strategies“. In: *Renewable and Sustainable Energy Reviews* 119 (2020). DOI: [10.1016/j.rser.2019.109596](https://doi.org/10.1016/j.rser.2019.109596) (siehe S. 3, 24).
- [Tsc19] TSCHÖKE, H.; GUTZMER, P. und PFUND, T., Hrsg.: *Elektrifizierung des Antriebsstrangs*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2019. DOI: [10.1007/978-3-662-60356-7](https://doi.org/10.1007/978-3-662-60356-7) (siehe S. 80).
- [Tut15] TUTUIANU, M.; BONNEL, P.; CIUFFO, B.; HANIU, T.; ICHIKAWA, N.; MAROTTA, A.; PAVLOVIC, J. und STEVEN, H.: „Development of the World-wide harmonized Light duty Test Cycle (WLTC) and a possible pathway for its introduction in the European legislation“. In: *Transportation Research Part D: Transport and Environment* 40.27 (2015), S. 61–75. DOI: [10.1016/j.trd.2015.07.011](https://doi.org/10.1016/j.trd.2015.07.011) (siehe S. 101).
- [Ueb14] UEBEL, S.; TEMPELHAHN, C.; LIEBERS, M.; KUTTER, S. und BÄKER, B.: „Anwendung der Variationsrechnung für Steuerungsaufgaben im Kraftfahrzeug“. In: *at – Automatisierungstechnik* 62.4 (2014). DOI: [10.1515/auto-2013-1055](https://doi.org/10.1515/auto-2013-1055) (siehe S. 16).
- [USG23] USGS: *EarthExplorer*. U.S.Geological Survey, 2023. URL: <https://earthexplorer.usgs.gov>. Zugriff am 25. März 2023 (siehe S. 240).
- [Vad16] VADAMALU, R. S. und BEIDL, C.: „Explicit MPC PHEV Energy Management using Markov Chain Based Predictor: Development and Validation at Engine-In-The-Loop Testbed“. In: *European Control Conference, Aalborg, Denmark, June 29 - July 1* (2016), S. 453–458. DOI: [10.1109/ECC.2016.7810326](https://doi.org/10.1109/ECC.2016.7810326) (siehe S. 54).
- [Vor19] VORA, A. P.; JIN, X.; HOSHING, V.; SHAVER, G.; VARIGONDA, S. und TYNER, W. E.: „Integrating battery degradation in a cost of ownership framework for hybrid electric vehicle design optimization“. In: *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering* 233.6 (2019), S. 1507–1523. DOI: [10.1177/0954407018802663](https://doi.org/10.1177/0954407018802663) (siehe S. 80).

- [Wah15] WAHL, H.-G.: „Optimale Regelung eines prädiktiven Energiemanagements von Hybridfahrzeugen“. Dissertation. Karlsruhe: Karlsruher Institut für Technologie, 2015 (siehe S. 28, 32, 39, 54, 85, 146).
- [Wan19] WANG, S.; HUANG, X.; LOPEZ, J. M.; XU, X. und DONG, P.: „Fuzzy Adaptive-Equivalent Consumption Minimization Strategy for a Parallel Hybrid Electric Vehicle“. In: *IEEE Access* 7 (2019), S. 133290–133303. DOI: [10.1109/ACCESS.2019.2941399](https://doi.org/10.1109/ACCESS.2019.2941399) (siehe S. 27).
- [Wei18] WEIß, F.: „Optimale Konzeptauslegung elektrifizierter Fahrzeugantriebsstränge“. Dissertation. Chemnitz: Technische Universität Chemnitz, 2018 (siehe S. 12, 13, 37).
- [Wer23] WERRA, M.: „Potentiale prädiktiver Betriebsstrategien für elektrifizierte Antriebe“. Dissertation. Braunschweig: Technische Universität Braunschweig, 2023 (siehe S. 54, 55).
- [Wer88] WERBOS, P. J.: „Generalization of Backpropagation with Application to a Recurrent Gas Market Model“. In: *Neural Networks, Vol. 1* (1988), S. 339–356. DOI: [10.1016/0893-6080\(88\)90007-X](https://doi.org/10.1016/0893-6080(88)90007-X) (siehe S. 48).
- [Wu19] WU, J.; ZOU, Y.; ZHANG, X.; LIU, T.; KONG, Z. und HE, D.: „An Online Correction Predictive EMS for a Hybrid Electric Tracked Vehicle Based on Dynamic Programming and Reinforcement Learning“. In: *IEEE Access* 7 (2019), S. 98252–98266. DOI: [10.1109/ACCESS.2019.2926203](https://doi.org/10.1109/ACCESS.2019.2926203) (siehe S. 26).
- [Xia17] XIANG, C.; DING, F.; WANG, W. und HE, W.: „Energy management of a dual-mode power-split hybrid electric vehicle based on velocity prediction and nonlinear model predictive control“. In: *Applied Energy* 189 (2017), S. 640–653. DOI: [10.1016/j.apenergy.2016.12.056](https://doi.org/10.1016/j.apenergy.2016.12.056) (siehe S. 54).
- [Xia21] XIA, J.; WANG, F. und XU, X.: „A Predictive Energy Management Strategy for Multi-mode Plug-in Hybrid Electric Vehicle

- based on Long short-term Memory Neural Network“. In: *IFAC-PapersOnLine* 54.10 (2021), S. 132–137. DOI: [10.1016/j.ifacol.2021.10.153](https://doi.org/10.1016/j.ifacol.2021.10.153) (siehe S. 54).
- [Xie17] XIE, S.; HE, H. und PENG, J.: „An energy management strategy based on stochastic model predictive control for plug-in hybrid electric buses“. In: *Applied Energy* 196 (2017), S. 279–288. DOI: [10.1016/j.apenergy.2016.12.112](https://doi.org/10.1016/j.apenergy.2016.12.112) (siehe S. 54).
- [Xie18a] XIE, S.; HU, X.; QI, S. und LANG, K.: „An artificial neural network-enhanced energy management strategy for plug-in hybrid electric vehicles“. In: *Energy* 163 (2018), S. 837–848. DOI: [10.1016/j.energy.2018.08.139](https://doi.org/10.1016/j.energy.2018.08.139) (siehe S. 27, 29, 54, 133).
- [Xie18b] XIE, S.; HU, X.; XIN, Z. und LI, L.: „Time-Efficient Stochastic Model Predictive Energy Management for a Plug-In Hybrid Electric Bus With an Adaptive Reference State-of-Charge Advisory“. In: *IEEE Transactions on Vehicular Technology* 67.7 (2018), S. 5671–5682. DOI: [10.1109/TVT.2018.2798662](https://doi.org/10.1109/TVT.2018.2798662) (siehe S. 54).
- [Xie19] XIE, S.; HU, X.; XIN, Z. und BRIGHTON, J.: „Pontryagin’s Minimum Principle based model predictive control of energy management for a plug-in hybrid electric bus“. In: *Applied Energy* 236 (2019), S. 893–905. DOI: [10.1016/j.apenergy.2018.12.032](https://doi.org/10.1016/j.apenergy.2018.12.032) (siehe S. 38, 54).
- [Xu19] XU, N.; KONG, Y.; CHU, L.; JU, H.; YANG, Z.; XU, Z. und XU, Z.: „Towards a Smarter Energy Management System for Hybrid Vehicles: A Comprehensive Review of Control Strategies“. In: *Applied Sciences* 9.10 (2019). DOI: [10.3390/app9102026](https://doi.org/10.3390/app9102026) (siehe S. 24).
- [Yan20] YANG, C.; YOU, S.; WANG, W.; LI, L. und XIANG, C.: „A Stochastic Predictive Energy Management Strategy for Plug-in Hybrid Electric Vehicles Based on Fast Rolling Optimization“. In: *IEEE Transactions on Industrial Electronics* 67.11 (2020), S. 9659–9670. DOI: [10.1109/TIE.2019.2955398](https://doi.org/10.1109/TIE.2019.2955398) (siehe S. 29, 42, 54).

- [Yin19] YIN, Y.; RAN, Y.; ZHANG, L.; PAN, X. und LUO, Y.: „An Energy Management Strategy for a Super-Mild Hybrid Electric Vehicle Based on a Known Model of Reinforcement Learning“. In: *Journal of Control Science and Engineering* 2019.4 (2019). DOI: [10.1155/2019/9259712](https://doi.org/10.1155/2019/9259712) (siehe S. 26).
- [Yuf19] YUFANG, L.; MINGNUO, C. und WANZHONG, Z.: „Investigating long-term vehicle speed prediction based on BP-LSTM algorithms“. In: *IET Intelligent Transport Systems* 13.8 (2019), S. 1281–1290. DOI: [10.1049/iet-its.2018.5593](https://doi.org/10.1049/iet-its.2018.5593) (siehe S. 41, 42).
- [Zen15] ZENG, X. und WANG, J.: „A Parallel Hybrid Electric Vehicle Energy Management Strategy Using Stochastic Model Predictive Control With Road Grade Preview“. In: *IEEE Transactions on Control Systems Technology* 23.6 (2015), S. 2416–2423. DOI: [10.1109/TCST.2015.2409235](https://doi.org/10.1109/TCST.2015.2409235) (siehe S. 29, 54).
- [Zha16a] ZHANG, F.; LIU, H.; HU, Y. und XI, J.: „A Supervisory Control Algorithm of Hybrid Electric Vehicle Based on Adaptive Equivalent Consumption Minimization Strategy with Fuzzy PI“. In: *Energies* 9.11 (2016). DOI: [10.3390/en9110919](https://doi.org/10.3390/en9110919) (siehe S. 27).
- [Zha16b] ZHANG, F.; XI, J. und LANGARI, R.: „An adaptive equivalent consumption minimization strategy for parallel hybrid electric vehicle based on Fuzzy PI“. In: *IEEE Intelligent Vehicles Symposium, Gothenburg, Sweden, June 19-22* (2016), S. 460–465. DOI: [10.1109/IVS.2016.7535426](https://doi.org/10.1109/IVS.2016.7535426) (siehe S. 27).
- [Zha17] ZHANG, S.; XIONG, R. und SUN, F.: „Model predictive control for power management in a plug-in hybrid electric vehicle with a hybrid energy storage system“. In: *Applied Energy* 185 (2017), S. 1654–1662. DOI: [10.1016/j.apenergy.2015.12.035](https://doi.org/10.1016/j.apenergy.2015.12.035) (siehe S. 53).
- [Zha18] ZHANG, F.; XU, K.; LI, L. und LANGARI, R.: „Comparative Study of Equivalent Factor Adjustment Algorithm for Equivalent Consumption Minimization Strategy for HEVs“. In: *IEEE Vehicle Power and Propulsion Conference (VPPC), Chicago, IL, USA, August 27-30* (2018). DOI: [10.1109/VPPC.2018.8604986](https://doi.org/10.1109/VPPC.2018.8604986) (siehe S. 27, 53).

- [Zha19] ZHAO, B.; LV, C. und HOFMAN, T.: „Driving-Cycle-Aware Energy Management of Hybrid Electric Vehicles Using a Three-Dimensional Markov Chain Model“. In: *Automotive Innovation* 2.2 (2019), S. 146–156. DOI: [10.1007/s42154-019-00059-z](https://doi.org/10.1007/s42154-019-00059-z) (siehe S. 54).
- [Zhe14] ZHENG, C. H.; XU, G. Q.; CHA, S. W. und LIANG, Q.: „Numerical Comparison Of Ecms And Pmp-Based Optimal Control Strategy In Hybrid Vehicles“. In: *International Journal of Automotive Technology*, Vol. 15, No. 7 (2014), S. 1189–1196. DOI: [10.1007/s12239-014-0124-5](https://doi.org/10.1007/s12239-014-0124-5) (siehe S. 27, 53).
- [Zho21] ZHOU, Q. und DU, C.: „A quantitative analysis of model predictive control as energy management strategy for hybrid electric vehicles: A review“. In: *Energy Reports* 7 (2021), S. 6733–6755. DOI: [10.1016/j.egy.2021.09.119](https://doi.org/10.1016/j.egy.2021.09.119) (siehe S. 28, 41, 54).

Eigene Publikationen

Dieser Abschnitt enthält ein vollständiges Verzeichnis der eigenen Veröffentlichungen. Die Publikationen [1] und [3] beschreiben generische Prädiktionsalgorithmen für den Einsatz in EMS, während die Publikation [2] einen umfassenden Überblick über EMS in elektrifizierten Fahrzeugen gibt. Dies umfasst sowohl EMS für die Systemauslegung als auch ein Ansatz für eine robuste, nichtprädiktive Online-ECMS. Ebenso ist in der Publikation [2] eine Methodik zur Erweiterung der nichtprädiktiven Online-ECMS um prädiktive Eigenschaften beschrieben. Zusätzlich wird in Publikation [4] ein alternativer Ansatz für eine prädiktive Online-ECMS vorgestellt. [5] verweist auf den zugehörigen Konferenzbeitrag. Der Beitrag der Mitautoren Herr Jhaveri, Herr Freund und Herr Harter umfasste neben allgemeinen Recherchearbeiten die Unterstützung bei der softwaretechnischen Umsetzung. Herr Harter hat im Rahmen seiner Abschlussarbeit [S3] außerdem wesentliche Teile der - in Anhang I aufgezeigten und als Teil von Publikation [3] veröffentlichten - Methodik zur Aufbereitung von GNSS-Realfahrdaten entwickelt. Ebenso erfolgte im Rahmen seiner Arbeit eine erste Zusammenstellung der Einflüsse auf das Fahrprofil aus Kapitel 3.4.2, welche in abgewandelter Form für [3] und die vorliegende Dissertation übernommen wurde. Herr Prof. Dr. rer. nat. Gauterin und Herr Dr.-Ing. Gießler übernahmen die Beaufsichtigung der angestellten Arbeiten.

- [1] DEUFEL, F.; GIEßLER, M. und GAUTERIN, F.: „A Generic Prediction Approach for Optimal Control of Electrified Vehicles Using Artificial Intelligence“. In: *Vehicles* 4.1 (2022), S. 182–198. DOI: [10.3390/vehicles4010012](https://doi.org/10.3390/vehicles4010012).

- [2] DEUFEL, F.; GIEßLER, M. und GAUTERIN, F.: „Optimal Control of Electrified Powertrains in Offline and Online Application Concerning Dimensioning of Li-Ion Batteries“. In: *Vehicles* 4.2 (2022), S. 464–481. DOI: [10.3390/vehicles4020028](https://doi.org/10.3390/vehicles4020028).
- [3] DEUFEL, F.; JHAVERI, P.; HARTER, M.; GIEßLER, M. und GAUTERIN, F.: „Velocity Prediction Based on Map Data for Optimal Control of Electrified Vehicles Using Recurrent Neural Networks (LSTM)“. In: *Vehicles* 4.3 (2022), S. 808–824. DOI: [10.3390/vehicles4030045](https://doi.org/10.3390/vehicles4030045).
- [4] DEUFEL, F.; FREUND, M. und GAUTERIN, F.: „A Novel Approach for a Predictive Online ECMS Applied in Electrified Vehicles Using Real Driving Data“. In: *World Electric Vehicle Journal* 14.12 (2023), S. 353. DOI: [10.3390/wevj14120353](https://doi.org/10.3390/wevj14120353).
- [5] DEUFEL, F.; FREUND, M. und GAUTERIN, F.: „A Novel Approach for a Predictive Online ECMS Applied in Electrified Vehicles Using Real Driving Data“. In: *EVS36 International Electric Vehicle Symposium and Exhibition, Sacramento, CA, USA, June 11-14 (2023)*. URL: https://evs36.com/wp-content/uploads/finalpapers/FinalPaper_Deufel_Felix.pdf. Zugriff am 1. September 2023.

Betreute studentische Arbeiten

Dieser Abschnitt listet die während der Zeit als Doktorand am Institut für Fahrzeugsystemtechnik des Karlsruher Institut für Technologie (KIT) betreuten studentischen Arbeiten auf. Inhalte, die aus Abschlussarbeiten entnommen wurden, wurden durch einen entsprechenden Verweis im Fließtext kenntlich gemacht.

- [S1] TAN, Qingyu: *Enhancement of a simulation model to investigate 48 V hybrid electric vehicles and implementation of an optimization-based operating strategy*. Masterarbeit. 2020.
- [S2] FIGLESTÄHLER, Max: *Weiterentwicklung einer Fahrstrategie für 48V-Hybridfahrzeuge unter Verwendung der Methode des Reinforcement Learning*. Bachelorarbeit. 2021.
- [S3] HARTER, Marius: *Vorhersage des Geschwindigkeitsverlaufs zur Anwendung prädiktiver Fahrstrategien bei elektrifizierten Fahrzeugantrieben*. Masterarbeit. 2021.
- [S4] JHAVERI, Purav: *Stochastic Model Predictive Control applied to 48V hybrid electric vehicles: Analysis of the state-of-the-art and Implementation in a simulation model*. Bachelorarbeit. 2021.
- [S5] LAPORTA, Riccardo: *Bewertender Vergleich von Fahrstrategien für elektrifizierte Fahrzeugantriebe (48V-System)*. Seminararbeit. 2021.
- [S6] VILLÁM, András: *Evaluation of derating strategies for batteries in electrified vehicle drives (48V system)*. Masterarbeit. 2021.
- [S7] BUCHER, Jan: *Simulationsgestützte Untersuchung der optimalen Fahrstrategie für das Modell eines 48 V Hybriden mit zeitvarianten Eigenschaften*. Bachelorarbeit. 2022.

- [S8] FREUND, Malte: *Simulationsgestützte Untersuchung prädiktiver Fahrstrategien in elektrifizierten Fahrzeugantrieben (48V System)*. Bachelorarbeit. 2022.
- [S9] ELBADAWI, Abdelrahman: *Simulative comparison of selected algorithms for optimal energy management of electrified vehicles in powertrain design*. Bachelorarbeit. 2023.
- [S10] KAPADIA, Siddharth: *Development of a real-time Energy Management Strategy based on Dynamic Programming for application in electrified vehicle drives*. Masterarbeit. 2023.
- [S11] VYAS, Rishabh: *Comparison of selected online-capable driving strategies for electrified vehicle drives (48 V hybrid system)*. Masterarbeit. 2023.

Abbildungsverzeichnis

1.1	Allgemeines V-Modell aus dem <i>Systems Engineering</i> mit Fokus der vorliegenden Arbeit. Angelehnt an VDI 2206 [Gau02].	2
1.2	Übersicht über die drei vorgestellten Forschungsfelder mit Fokus auf die verwendete Software sowie die Einbindung vorhandener Modelle und Toolboxes.	7
2.1	HEV-Topologien in Parallelkonfiguration aus Deufel et al. [2].	10
2.2	Wechselwirkungen des 48 V-Systems mit Fahrzeug, Fahrer und Fahrumgebung in Anlehnung an [För21].	11
2.3	Getriebeverluste $T_{GB,loss}$ in Nm für Kurbelwellendrehmomente $T_{CS} = 0...300$ Nm dargestellt über der Kurbelwellendrehzahl n_{CS} . Jeweils für alle Gänge inklusive DT (links). Hochschaltgeschwindigkeiten $v_{upshift}$ für die Gänge 1-8 in Abhängigkeit der Fahrpedalstellung APP (rechts). Hochschaltgeschwindigkeiten > 250 km/h sind gestrichelt dargestellt. Die Achsen sind teilweise normiert dargestellt. Der Wert 100 % entspricht dem maximalen Getriebeverlustmoment bzw. der maximalen Kurbelwellendrehzahl in der Darstellung.	15

2.4	Stationäres Verbrennungsmotorkennfeld (links). Schleppeistung und Schleppmoment der VKM (rechts). Die Achsen sind teilweise normiert dargestellt. Der Wert 100 % entspricht dem maximalen Motordrehmoment (links) und dem maximalen Schleppmoment (rechts) in der Darstellung. Ebenso entspricht 100 % jeweils der maximal dargestellten Motordrehzahl.	16
2.5	Elektromotorkennfeld (inkl. Leistungselektronik) für eine Spannung von 40 V (links) und 52 V (rechts) mit einer maximalen Leistung von 15 kW. Die Achsen sind teilweise normiert dargestellt. Der Wert 100 % entspricht dem maximalen Motordrehmoment bzw. der maximalen Motordrehzahl in der Darstellung.	17
2.6	Einfaches Ersatzschaltbild der Batterie.	18
2.7	Links: Verwendete zwölf Realfahrzyklen, sortiert nach drei Fahrertypen: <i>aggressive</i> (oben), <i>average</i> (mitte), <i>mild</i> (unten) aus [För21]. Jeweils für vier verschiedene Fahrumgebungen dargestellt. Rechts: Nummerierung der zwölf Realfahrzyklen.	21
3.1	Prinzipskizze zum Bestärkenden Lernen, <i>Reinforcement Learning</i> (RL). Basierend auf [Sut15, Agg18, Mat23].	25
3.2	Visualisierung der Matrizen für die Rückwärtsrechnung der DP bei I Zustandsgrößen und K Steuergrößen.	32
3.3	Grundlegendes Prinzip der DP (links) im Vergleich zur Offline-ECMS (rechts) unter Verwendung des Schießverfahrens (engl.: <i>Shooting Method</i>). Aus Deufel et al. [2].	35
3.4	Grundprinzip einer Modellprädiktiven Regelung (MPC) mit dem Prädiktionshorizont τ_{pred} und dem Steuerungshorizont $\tau_{control}$ aus Deufel et al. [1]. Vereinfachte Darstellung basierend auf [Fin02, Dit06].	40

3.5	Überblick über die Einflüsse auf das Fahrgeschwindigkeitsprofil, angelehnt an Deufel et al. [3]. . . .	44
3.6	Visualisierung der Übergangswahrscheinlichkeitsmatrix (engl. <i>Transition Probability Matrix</i> , kurz TPM) aus Deufel et al. [1].	45
3.7	Grundlegende Architektur eines Perzeptrons aus Deufel et al. [1] in Anlehnung an [Agg18].	46
3.8	Rekurrentes Neuronales Netz (RNN) aus Deufel et al. [1] in Anlehnung an [Agg18].	47
3.9	Architektur einer LSTM-Zelle eines Rekurrenten Neuronalen Netzes (RNN) aus Deufel et al. [3]. Basierend auf [Che18].	49
4.1	Analyse der Batterieeigenschaften eines typischen 48 V-Systems. Die Sprünge im Konturplot von $\frac{\partial \text{SOC}}{\partial \text{SOC}}$ zwischen 50 % und 60 % resultieren aus dem Verlauf von U_{OCV} . Die Achsen sind teilweise normiert dargestellt. Der Wert 100 % entspricht der maximalen Leerlaufspannung U_{OCV} bzw. dem maximalen inneren Widerstand R_i in der Darstellung.	58
4.2	Vergleich eines konstanten gegenüber einem dynamischen Äquivalenzfaktors λ bei der Offline-ECMS mit der Originalbatterie mit 1000 Wh und SOC-abhängigen Eigenschaften. Dargestellt für einen exemplarischen Realfahrzyklus aus Abbildung 2.7.	59
4.3	Visualisierung der berücksichtigten Betriebsmodi basierend auf der festgelegten Definition des Steuergroßenvektors anhand der vereinfachten Kennfelder von EM und VKM. Berücksichtigte Bereiche in grün (EM) bzw. blau (VKM) markiert. Auf die Darstellung des Schleppmoments der VKM wird verzichtet.	63

4.10	CO ₂ -Emissionen über der VKM-Mindestlaufzeit beim Realfahrzyklus <i>urban low mild</i> (Realfahrzyklus Nr. 3 aus Abbildung 2.7) für eine P2-Topologie. Die Achsen sind teilweise normiert dargestellt. Der Wert 100 % entspricht den maximalen CO ₂ -Emissionen in der Darstellung.	78
4.11	Rechenzeiten über VKM-Mindestlaufzeit DP (links) und Offline-ECMS (rechts) bei Realfahrzyklus <i>urban low mild</i> (Realfahrzyklus Nr. 3 aus Abbildung 2.7) für eine P2-Topologie.	79
4.12	Relativbetrachtung des minimalen Kraftstoffverbrauchs von Offline-ECMS und DP bei Begrenzung des nutzbaren Energieinhaltes der Batterie E_{bat} auf 25 Wh, 100 Wh und 1000 Wh. 100 % entsprechen jeweils der DP-Lösung. Realfahrzyklen entsprechend 2.7.	81
5.1	Methodik zur Auslegung einer robusten, echtzeitfähigen Online-ECMS.	86
5.2	Vergleich der Äquivalenzfaktoren der robusten, echtzeitfähigen Online-ECMS für die Topologien P1,P2,P14, P24. Realfahrzyklen entsprechend Abbildung 2.7.	89
5.3	Visualisierung der CO ₂ -Emissionen für eine P1-Topologie für die zwölf Realfahrzyklen entsprechend Abbildung 2.7: Parameterstudie für die Online-ECMS bei k_{pSOC} von 0 bis 200. Die Achsen sind teilweise normiert dargestellt. Der Wert 100 % entspricht den jeweils maximalen dargestellten CO ₂ -Emissionen.	90
5.4	Visualisierung des genutzten Energieinhalts der Batterie, ausgedrückt durch $\Delta SOC_{min,max}$ für eine P1-Topologie für die zwölf Realfahrzyklen entsprechend Abbildung 2.7: Parameterstudie für die Online-ECMS bei k_{pSOC} von 0 bis 200.	91

5.5	Visualisierung der Endenergieabweichung $\Delta E_{CS,end}$ in Wh für eine P1-Topologie für die zwölf Realfahrzyklen entsprechend Abbildung 2.7: Eine Endenergieabweichung zum Ende des Fahrzyklus von $\Delta E_{CS,end} = 0$ ist mit einer gestrichelten Linie gekennzeichnet. Parameterstudie für die Online-ECMS bei kp_{SOC} von 0 bis 200.	92
5.6	Exemplarische Visualisierung der Endenergieabweichung $\Delta E_{CS,end}$ in Wh für einen Realfahrzyklus aus Abbildung 5.5 zur Identifikation von $kp_{SOC,CS}$ (im weiteren Verlauf der Arbeit kurz: kp_{SOC}). Der zulässige Bereich für $\Delta E_{CS,end}$ ist eingetragen.	93
5.7	Ergebnisse der Online-ECMS im Vergleich zur global optimalen Lösung (Offline-ECMS) hinsichtlich CO_2 -Emissionen. Negative Werte bedeuten eine Verschlechterung der Online-ECMS gegenüber der Offline-ECMS. Realfahrzyklen entsprechend Abbildung 2.7.	95
5.8	Zielkonflikt CO_2 -Einsparpotential und Fahrkomfort, repräsentiert durch VKM-Starts beim Realfahrzyklus <i>urban low mild</i> (Realfahrzyklus Nr. 3 aus Abbildung 2.7) für eine P2-Topologie für die Online-ECMS im Vergleich zu den Lösungen der Offline-ECMS und der DP aus der Offline-Optimierung. Die Achsen sind teilweise normiert dargestellt. Der Wert 100 % entspricht den maximalen CO_2 -Emissionen in der Darstellung (Online-ECMS).	96
5.9	Überblick über die 40 Fahrzyklen aus dem <i>Datensatz zur Validierung</i> der Online-ECMS.	98
5.10	Kenndaten der 34 ausgewählten Fahrzyklen aus dem <i>Datensatz zur Validierung</i> der Online-ECMS. Die Achsen sind teilweise normiert dargestellt. Der Wert 100 % entspricht dem maximalen Kraftstoffbedarf in der Darstellung.	99

5.11	Effektiver, dynamischer Radhalbmesser $r_{dyn,eff}$ im Vergleich zu $r_{dyn,theo} = 0.342$ m aus Datenblatt für untersuchtes F-Segment Fahrzeug (vertikale Linie). Messpunkte aus <i>Datensatz zur Validierung</i> (Abbildung 5.10).	101
5.12	Rollwiderstand und Luftwiderstand für das Testfahrzeug bis 100 km/h. Ab ca. 70 km/h fällt der Luftwiderstand höher aus als der Rollwiderstand.	102
5.13	Parameterstudie zum Korrekturfaktor Masse für das Gütekriterium RMSE Leistung P_{CS} , Abweichung mech. Energie E_{CS} und die mittlere Abweichung von P_{CS} . Fahrzyklen aus <i>Datensatz zur Validierung</i> entsprechend Abbildung 5.10.	104
5.14	Effektiv auftretende Übersetzungen aus Messungen, aufsteigend sortiert. Übersetzungen aus Getriebe und Differentialgetriebe für die Gänge 1-6 waagrecht eingezeichnet. Messungen aus <i>Datensatz zur Validierung</i> , vgl. Abbildung 5.10.	105
5.15	Einfluss einer erhöhten Hochschaltgeschwindigkeit an einem exemplarischen Segment eines Fahrzyklus aus dem <i>Datensatz zur Validierung</i> (Abbildung 5.10). Es ist deutlich zu erkennen, dass mit der im Modell hinterlegten Schaltstrategie (links) ein früheres Hochschalten erfolgt (orangene Kurve). In der Messung hingegen (blaue Kurve) erfolgt erst ein späteres Hochschalten. Teilweise werden die höheren Gänge gar nicht eingelegt ($t = 820$ s bis $t = 930$ s). Durch eine Erhöhung der Hochschaltgeschwindigkeit kann die Übereinstimmung deutlich verbessert werden (rechts). . .	106

5.16	Berechnung des Kennfeldes der VKM aus dem <i>Datensatz zur Validierung</i> (Abbildung 5.10). Links sind die Messpunkte dargestellt, rechts die errechneten Wirkungsgrade. Das in der Simulation hinterlegte Kennfeld wurde bereits in Abbildung 2.4 eingeführt. Die Achsen sind teilweise normiert dargestellt. Der Wert 100 % entspricht dem maximalen Motordrehmoment in der Darstellung. Ebenso entspricht 100 % jeweils der maximal dargestellten Motordrehzahl.	107
5.17	Vergleich gemessene Batterieladezustände mit den Batterieladezuständen, die sich durch Integration des gemessenen Batteriestroms ergeben (links). Resultierende Energieabweichung ΔE_{CS} in der Batterie, basierend auf dem einfachen Ersatzschaltbild (rechts). Dargestellt für einen exemplarischen Fahrzyklus des <i>Datensatz zur Validierung</i> aus Abbildung 5.10.	109
5.18	Finaler Batterieladezustand über dem initialen Ladezustand der Batterie (links) aus Messungen. Endenergieabweichungen unter Annahme einer konstanten Umrechnung von 9.25 Wh/1% SOC (rechts). Dargestellt für den <i>Datensatz zur Validierung</i> aus Abbildung 5.10.	110
5.19	Leistung Nebenverbraucher für alle vier Quadranten, die sich aus Laden/ Entladen der Batterie sowie motorischem und generatorischem Betrieb der EM ergeben. Häufigkeiten (links), Boxplots (rechts). Basierend auf dem <i>Datensatz zur Validierung</i> aus Abbildung 5.10.	112
5.20	Endenergieabweichung ΔE_{CS} in Wh der Online-ECMS für die 34 Fahrzyklen aus der Messung (<i>Datensatz zur Validierung</i>) entsprechend Abbildung 5.10. . .	115

5.21	Ergebnisse der Online-ECMS im Vergleich zur global optimalen Lösung (Offline-ECMS) für die 34 Fahrzyklen aus der Messung hinsichtlich CO ₂ -Emissionen (<i>Datensatz zur Validierung</i> entsprechend Abbildung 5.10). Negative Werte bedeuten eine Verschlechterung der Online-ECMS gegenüber der Offline-ECMS.	116
5.22	Vergleich des genutzten Energieinhalts der Batterie $\Delta E_{CS,min,max}$ der Online-ECMS im Vergleich zur EMS des Testfahrzeugs. Fahrzyklen aus Messung entsprechend Abbildung 5.10 (<i>Datensatz zur Validierung</i>).	117
5.23	Vergleich der errechneten CO ₂ -Werte für ausgewählte Fahrzyklen aus der Messung (<i>Datensatz zur Validierung</i>). Nach der Korrektur der Basisverbräuche verbleibt in den betrachteten Fahrzyklen eine Differenz zur Messung (schwarze Balken gegenüber türkisfarbene Balken). Dargestellt für sieben ausgewählte Fahrzyklen aus Abbildung 5.10. Die Achsen sind teilweise normiert abgebildet. Der Wert 100 % entspricht den maximalen CO ₂ -Emissionen in der Darstellung.	120
5.24	Histogramm der Motordrehmomente T_{ICE} für einen exemplarischen Fahrzyklus. Zusätzlich sind die Wirkungsgrade η_{ICE} in Abhängigkeit des Drehmomentes T_{ICE} aufgetragen. Dargestellt für einen exemplarischen Fahrzyklus aus Abbildung 5.10 (<i>Datensatz zur Validierung</i>).	122
5.25	Histogramm der gefahrenen Wirkungsgrade der VKM η_{ICE} . Dargestellt für einen exemplarischen Fahrzyklus aus Abbildung 5.10 (<i>Datensatz zur Validierung</i>).	122

5.26	Analyse Lastpunktanhebung (LPAn) Messung gegenüber der ECMS in Simulation: Summendrehmoment an der Kurbelwelle (oben), Drehmoment der EM (mitte) und Drehmoment der VKM (unten) für Betriebspunkte, welche die Bedingung aus Formel 5.16 erfüllen. Dargestellt für einen exemplarischen Fahrzyklus des <i>Datensatzes zur Validierung</i> (vgl. Abbildung 5.10).	123
5.27	Rechendauern der robusten Online-ECMS zur Berechnung der Drehmomentverteilung. Dargestellt für alle vier untersuchten Topologien P1 (links, oben), P2 (rechts, oben), P14 (links, unten), P24 (rechts, unten) für einen exemplarischen Fahrzyklus aus dem <i>Datensatz zur Validierung</i> (Abbildung 5.10).	127
6.1	FFNN zur Vorhersage von Fahrzeuggeschwindigkeit, Fahrzeugbeschleunigung und Fahrbahnsteigung, aus Deufel et al. [1].	134
6.2	Architektur des entwickelten ED-LSTM in einer mehrstufigen, multivariaten Anwendung für einen beispielhaften Vorhersagehorizont von 3 s. Aus Deufel et al. [3].	136
6.3	Vorhersagen mit MC ohne Fahrbahnsteigung aus Deufel et al. [1]. Dargestellt an einem exemplarischen Fahrzyklus aus dem <i>Alternativen Datensatz</i> (Abbildung H.1).	138
6.4	Vorhersagen mit FFNN ohne Fahrbahnsteigung aus Deufel et al. [1]. Dargestellt an einem exemplarischen Fahrzyklus aus dem <i>Alternativen Datensatz</i> (Abbildung H.1).	139
6.5	Beispielhafte Testsequenz mit ED-LSTM bei 20 s Vorhersagehorizont. Aus Deufel et al. [3]. Dargestellt an einem exemplarischen Fahrzyklus aus dem <i>Alternativen Datensatz</i> (Abbildung H.1).	141

6.6	Analyse eines unterschiedlichen Vorhersagehorizonts der prädiktiven Online-ECMS für zwei beispielhaften Sequenzen. Aus Deufel et al. [2]. Die Sequenzen sind dem Realfahrzyklus <i>urban low mild</i> (Realfahrzyklus Nr. 3 aus Abbildung 2.7) entnommen.	145
6.7	Analyse der Einführung eines Schwellenwerts für die prädiktive Online-ECMS beim Realfahrzyklus <i>urban low mild</i> (Realfahrzyklus Nr. 3 aus Abbildung 2.7): Die nichtprädiktive Online-ECMS ist in schwarz dargestellt, die prädiktive Online-ECMS in orange. Eine Berücksichtigung des Rekuperationspotentials, wie in Formel 6.2 eingeführt, führt ohne Schwellenwert zu einer kontinuierlichen Verringerung von λ für die prädiktive Online-ECMS (orange). Mit Schwellenwert sind jedoch gezielte Entladungen realisierbar, vgl. SOC-Verlauf, rechts. Aus Deufel et al. [2].	147
A.1	Ablauf der DP.	206
B.1	Darstellung der Matrizenarchitektur bei der Rückwärtsrechnung für bis zu zwei Zustands- und Steuergrößen.	208
C.1	Umsetzung der PMP am einfachen Praxisbeispiel. Die Gesamtkosten betragen für Fall 1 jeweils $J_{DP}^* = 0.22513$ g und $J_{PMP}^* = 0.22513$ g, sowie für Fall 2 $J_{DP}^* = 0.24715$ g und $J_{PMP}^* = 0.24719$ g.	218

D.1	Visualisierung ausgewählter physikalischer Größen zur Validierung des DP-Modells über der Zeit mittels des bestehenden ECMS-Modells, P2 (oben) und P24 (unten) für $N_{X_1} = 401$ im Realfahrzyklus <i>urban low mild</i> (Realfahrzyklus Nr. 3 aus Abbildung 2.7). Die Lösung der DP ist jeweils mittels der blauen Kurve dargestellt. Die Lösung der Offline-ECMS ist über die orangene Kurve gegeben.	221
E.1	Zielkonflikt CO ₂ -Einsparpotential und Fahrkomfort, repräsentiert durch VKM-Starts beim Realfahrzyklus <i>urban low mild</i> (Realfahrzyklus Nr. 3 aus Abbildung 2.7) für eine P2-Topologie mit Hysterese $E_{stsp,hyst}$	224
F.1	CO ₂ über kp_{SOC} (P2).	227
F.2	$\Delta SOC_{min,max}$ über kp_{SOC} (P2).	227
F.3	$\Delta E_{CS,end}$ über kp_{SOC} (P2).	227
F.4	CO ₂ über kp_{SOC} (P14).	227
F.5	$\Delta SOC_{min,max}$ über kp_{SOC} (P14).	227
F.6	$\Delta E_{CS,end}$ über kp_{SOC} (P14).	227
F.7	CO ₂ über kp_{SOC} (P24).	228
F.8	$\Delta SOC_{min,max}$ über kp_{SOC} (P24).	228
F.9	$\Delta E_{CS,end}$ über kp_{SOC} (P24).	228
G.1	Parameterstudien zur Korrektur des Masse und des Roll- bzw. Luftwiderstandbeiwerts. Dargestellt ist die Abweichung zwischen Simulations- und Messergebnis als RMSE der Kurbelwellenleistung. Fahrzyklen aus Messung entsprechend Abbildung 5.10 (<i>Datensatz zur Validierung</i>). . .	230
G.2	Auswirkung des Getriebekorrekturfaktors auf das Kennfeld.	231

G.3	Prozentuale Abweichung der im VKM-Kennfeld simulierten Betriebspunkte aus der Messung gegenüber dem tatsächlich gemessenen Kraftstoffverbrauch. Fahrzyklen aus Messung entsprechend Abbildung 5.10 (<i>Datensatz zur Validierung</i>).	232
G.4	Verläufe der Außentemperatur im jeweiligen Fahrzyklus über der Zeit (links). Durchschnittliche Nebenverbraucherleistung in Abhängigkeit der Außentemperatur (rechts). Dargestellt jeweils für die Fahrzyklen aus der Messung entsprechend Abbildung 5.10 (<i>Datensatz zur Validierung</i>).	233
G.5	Rekuperationsverhalten der optimalen EMS im Modell gegenüber der Messung im Realbetrieb. Dargestellt für einen exemplarischen Fahrzyklus aus Abbildung 5.10 (<i>Datensatz zur Validierung</i>).	234
H.1	Verteilung von Fahrzeuggeschwindigkeit, Fahrzeugbeschleunigung und Fahrbahnsteigung des <i>Alternativen Datensatzes</i> . Aus Deufel et al. [1].	236
I.1	Visualisierung der verfügbaren Fahrdaten aus dem <i>Alternativen Datensatz</i> . Aus Deufel et al. [3].	240
I.2	Visualisierung von SRTM-Datenpunkten in der Karte (links) und entsprechende Höhendaten (rechts) aus Deufel et al. [3].	241
I.3	Visualisierung der identifizierten OSM-Daten einschließlich GNSS-Track, Ampel, Vorfahrt gewähren und Stop. Außerdem wird die zulässige Höchstgeschwindigkeit korrekt erkannt, auch wenn sie richtungsabhängig ist (nicht dargestellt). Aus Deufel et al. [3].	241
I.4	Visualisierung der zweistufigen Filtermethode zur Fahrzeuggeschwindigkeitsberechnung anhand einer beispielhaften Sequenz. Aus Deufel et al. [3].	242

I.5	Rohdaten aus dem GNSS-Track aus I.1 (blau) sowie die geglätteten Daten (orange). Zusätzlich ist der approximierter Kreis eingezeichnet (grau) sowie der zugehörige Radius des Adenauerrings in Karlsruhe aus der Geometrie. Aus Deufel et al. [3].	244
I.6	Visualisierung der berechneten Peilung und Krümmung unter Verwendung des Tiefpassfilters für den GNSS-Track aus I.1 . Aus Deufel et al. [3].	244
I.7	Zweistufige Filtermethode zur Berechnung der Fahrbahnsteigung anhand einer Alpenüberquerung. Der in I.8 dargestellte Ausschnitt ist markiert. Aus Deufel et al. [3].	246
I.8	Ausgewählte Sequenz zur Validierung der zweistufigen Filtermethode zur Berechnung der Fahrbahnsteigung anhand einer Alpenüberquerung. Aus Deufel et al. [3].	246
J.1	Parameterstudie: RMSE für Fahrzeuggeschwindigkeit, Fahrzeugbeschleunigung und Fahrbahnsteigung in Abhängigkeit von der Diskretisierung der Markov-Zustände. Jeweils mit und ohne Fahrbahnsteigung α . Aus Deufel et al. [1].	250
J.2	Parameterstudie: RMSE für Fahrzeuggeschwindigkeit, Fahrzeugbeschleunigung und Fahrbahnsteigung in Abhängigkeit von der Anzahl der Neuronen in den versteckten Schichten. Jeweils mit und ohne Fahrbahnsteigung α . Aus Deufel et al. [1].	251

Tabellenverzeichnis

2.1	Fahrzeugsegmente für Personenkraftwagen entsprechend der Europäischen Kommission und dem deutschen Kraftfahrt-Bundesamt (Auswahl).	14
2.2	Parameter des verwendeten D-Segment Fahrzeugs.	15
3.1	Vergleich von Arbeiten über EMS von elektrifizierten Fahrzeugantrieben in der Literatur. Kategorisiert nach 1) EMS in der Systemauslegung 2) (Prädiktive) EMS für den Onlineeinsatz 3) Prädiktionen für den Onlineeinsatz 4) Berücksichtigte Optimierungsziele der EMS 5) Verwendung eines 48 V-Systems 6) Untersuchung realer Betriebsbedingungen.	53
4.1	Definition der Zustandsgrößen im DP-Algorithmus.	65
4.2	Prozentuale Abweichung des ermittelten Kraftstoffbedarfs zwischen Offline-ECMS und DP für eine Batterie mit 475 Wh und einer Stützstellenzahl von $N_{X_1} = 101$. Positive Werte bedeuten einen erhöhten Verbrauch der DP gegenüber der Offline-ECMS. Abweichungen größer 1 % sind grau markiert. Verwendete zwölf Realfahrzyklen entsprechend Abbildung 2.7.	66
4.3	Einstellungen DP-Algorithmus.	71
4.4	Kraftstoffbedarf für einen Start der VKM in Gramm (g), zusammengestellt in [S7].	75

5.1	Finale Parametrierung Online-ECMS für P1-, P2-, P14- und P24-Topologie unter Verwendung der zwölf Realfahrzyklen entsprechend Abbildung 2.7.	94
5.2	Finale Parametrierung Online-ECMS unter Verwendung der zwölf Realfahrzyklen aus Abbildung 2.7 für das Testfahrzeug in P1-Topologie.	114
D.1	Prozentualer Vergleich der CO ₂ -Emissionen über alle zwölf Fahrzyklen zwischen Offline-ECMS und DP. Die prozentualen Abweichungen liegen < 1 %. Realfahrzyklen entsprechend Abbildung 2.7. Die angegebenen CO ₂ -Emissionen sind auf den höchsten, auftretenden Wert normiert.	219
D.2	Vergleich der Rechenzeiten in Minuten über alle zwölf Fahrzyklen zwischen Offline-ECMS und DP. Der Faktor stellt das Verhältnis zwischen der Rechenzeit der DP und der Offline-ECMS dar. Realfahrzyklen entsprechend Abbildung 2.7.	220
D.3	Vergleich von $\Delta SOC_{min,max}$ über alle zwölf Realfahrzyklen zwischen Offline-ECMS und DP. Realfahrzyklen entsprechend Abbildung 2.7.	221
F.1	Vergleich der Äquivalenzfaktoren λ_0 aus der Offline-ECMS zur Bestimmung von $\lambda_{0,avg}$ für die Online-ECMS. Realfahrzyklen entsprechend Abbildung 2.7.	225
F.2	Ergebnisse Online-ECMS für P1, P2, P14, P24. Realfahrzyklen entsprechend Abbildung 2.7. Die angegebenen CO ₂ -Emissionen sind auf den höchsten, auftretenden Wert normiert.	228
H.1	<i>Alternativer Datensatz</i> zur Untersuchung prädiktiver EMS. Aus Deufel et al. [1].	235
J.1	Gewählte Diskretisierung für Fahrzeuggeschwindigkeit, Fahrzeugbeschleunigung und Fahrbahnsteigung bei MC.	249

J.2	Parameter für FFNN (ohne Steigung und mit Steigung) für 10 Sekunden Vorhersage. Aus Deufel et al. [1].	252
J.3	Parameter des RNN aus Deufel et al. [3].	252

A Praxisbeispiel Dynamische Programmierung: Rechenalgorithmus

Initialisierung

Mithilfe eines einfachen Praxisbeispiels wird nachfolgend das Prinzip der DP erläutert. Hierbei wird für einen Fahrzyklus bestehend aus vier Zeitschritten und einer Fahrzeugbeschleunigung von konstant $a = 1 \text{ m/s}^2$ die ideale Drehmomentaufteilung zwischen VKM und EM bestimmt. Die Simulationsschrittweite dT beträgt dabei 1 s. Als Steuergröße u wird der Anteil des Antriebsmoments des EM vom notwendigen Gesamtmoment zur Traktion $T_{req,CS}$ definiert und auf fünf Stufen diskretisiert. Als Zustandsgröße X_1 wird der Batterieladezustand SOC gewählt und auf drei Stufen ebenso diskretisiert. Der minimale Ladezustand wird zu $SOC_{min} = 40 \%$ festgelegt und der maximale Ladezustand zu $SOC_{max} = 60 \%$. Entsprechend der in Kapitel 3.2 beschriebenen Logik zur DP muss eine Kostenfunktion definiert werden. Diese repräsentiert die instantanen Kosten L_k bzw. C_k im Zeitschritt k (vgl. Formel 3.6 bzw. Formel 4.3). Als Kosten wird der sich aus der jeweiligen Steuergrößen- und Zustandskombination resultierende Kraftstoffmassenstrom ($\dot{m}_{fuel,k}$) gewählt. Ebenso müssen für jeden Zeitschritt k die unzulässigen Zustände I_k (engl. *Infeasible States*), also die mit den gegebenen Randbedingungen nicht erreichbaren Lösungen vom Modell ausgegeben werden (vgl. Formel 4.4). Betriebspunkte, die nicht gefahren werden können bzw. mit denen eine Einhaltung der Randbedingungen nicht möglich ist, werden auf $C = 1000 \text{ kg/s}$ gesetzt ($\mu_{inf} = 1000 \text{ kg/s}$, vgl. Kapitel 4.2.3). Der Endzustand soll möglichst dem Startzustand entsprechen (CS-Betrieb).

Rechenmechanismus

Beim DP-Algorithmus werden rückwärtsrechnend (also entgegen der Zeit) für jeden Zeitschritt k sukzessive für jede Kombination aus Zustand und Steuerung die im Fahrzeugmodell instantan auftretenden Kosten L_k bzw. C_k bestimmt. Gleichzeitig resultiert aus jeder Kombination von Zustand und Steuerung ein entsprechender Folgezustand x_{k+1} . Für jeden dieser sich ergebenden Folgezustände x_{k+1} besteht eine ideale SOC-Trajektorie an das Fahrzyklusende. Die Gesamtkosten der jeweils optimalen SOC-Trajektorie an das Fahrzyklusende, also die Kosten bis zur Zielerreichung, werden als *Cost-To-Go* Y bezeichnet (vgl. Formel 3.8). Betrachtet man den Zeitschritt k während der Rückwärtsrechnung, so ist Y für den vorherigen DP-Rechenschritt, also für den Folgezeitschritt des Fahrzyklus $k + 1$ bekannt. Dabei ist Y_{k+1} für die Gitterpunkte der Zustandsgröße X_1 gespeichert. Um die jeweiligen *Cost-To-Go* für die sich ergebenden individuellen Folgezustände x_{k+1} aus dem aktuellen Rechenschritt k zu bestimmen, müssen die für die festgelegten Zustände des DP-Gitters bereits bekannten, minimalen *Cost-To-Go* im nachfolgenden Zeitschritt (Y_{k+1}) hinsichtlich der sich ergebenden Zustände x_{k+1} interpoliert werden. Anschließend werden die instantanen Kosten des aktuellen Zeitschritts L_k bzw. C_k und die interpolierten *Cost-To-Go* des nachfolgenden Zeitschritts Y_{k+1} als *Cost-To-Go* im aktuellen Zeitschritt Y_k zusammengefasst. Entsprechend der minimalen *Cost-To-Go* im aktuellen Zeitschritt Y_k ergibt sich somit für jeden Zustand eine ideale Steuerung. Die minimalen *Cost-To-Go* im aktuellen Zeitschritt Y_k sowie die zugehörige ideale Steuerung u wird für jeden Gitterpunkt von X_1 gespeichert und analog für den nächsten Berechnungsschritt (also $k - 1$) berücksichtigt. Nachdem alle Zeitschritte durchlaufen wurden, wird die für jeden Zustand ermittelte, optimale Steuerung μ^* (Formel 3.9) in einem Vorwärtsdurchlauf (also mit der Zeit) auf den Fahrzyklus angewandt. Die wichtigsten Größen sind zum Verständnis in Abbildung A.1 dargestellt. Dies umfasst:

- Die Zustände für die Zustandsgröße X_1 .
- Die Steuerungen für die Steuergröße U .
- Die Formeln zur Bestimmung von T_{EM} , T_{ICE} und T_{brake} .

- Für alle Zustände und Steuerungen:
 - Die instantanen Kosten im Zeitschritt k L_k bzw. C_k .
 - Die *Cost-To-Go* im Folgezeitschritt $k+1$ (Y_{k+1}).
 - Die *Cost-To-Go* im Zeitschritt k (Y_k).
 - Die minimalen *Cost-To-Go* im Zeitschritt k (Y_k).
- Die optimalen Steuergrößen μ^* .
- Die ausgewählte Ergebnisse nach Anwendung des Vorwärtslaufs: U , X , C , T_{ICE} , T_{EM} und v_{soll} .

Zum besseren Verständnis sind dabei auch die in diesem Beispiel auftretenden Zahlenwerte hinterlegt.

Ergebnisse

Nachfolgend sind ausgewählte Ergebnisse aus dem Praxisbeispiel gelistet:

- Sobald die instantanen Kosten (L_k bzw. C_k) oder die *Cost-To-Go* im Folgezeitschritt Y_{k+1} ungültig sind, also mit dem Wert 1000 kg/s bzw. kg überschrieben werden, so ergibt sich auch für die *Cost-To-Go* im aktuellen Zeitschritt Y_k ein Wert von $Y_k = 1000$ kg (z. B. zum Zeitpunkt t_1).
- Ein Betrieb der VKM unter der Mindestdrehzahl führt zu unzulässigen Zuständen. Der Wert für die instantanen Kosten (L_k bzw. C_k) der entsprechenden Steuerungen beträgt 1000 kg/s (z. B. $u \neq 1$ zum Zeitpunkt t_1 , orange Markierung).
- Eine Entladung der Batterie bei $SOC_{min} = 40$ % wird ebenso mit instantanen Kosten L_k bzw. C_k von 1000 kg/s belegt wie ein Laden bei $SOC_{max} = 60$ % (grüne Markierung).
- Bei der Bestimmung der *Cost-To-Go* Y_k für reinen VKM-Betrieb ($u = 0$) entsprechen diese exakt den minimalen *Cost-To-Go* Y_{k+1} vom nachfolgenden Zeitschritt, da der Zustand unverändert bleibt ($x_{k+1} = x_k$, blaue Markierung). Die beschriebene Interpolation ist hier nicht notwendig.

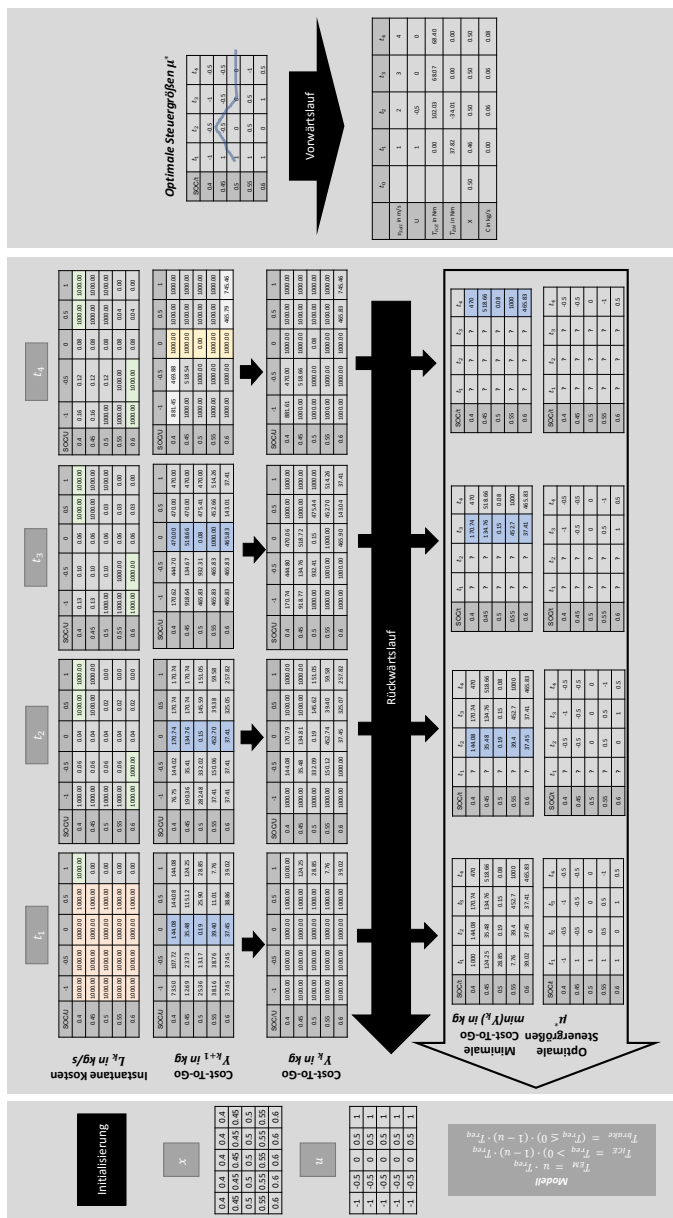


Abbildung A.1: Ablauf der DP.

B Praxisbeispiel Dynamische Programmierung: Matrizenarchitektur Rückwärtsrechnung

Nachfolgend ist ergänzend zu Abbildung 3.2 aus Kapitel 3.2 der Aufbau der Matrizen in der Rückwärtsrechnung bei der DP mit bis zu zwei Zustands- und Steuergrößen dargestellt (Abbildung B.1). Ebenso sind die zugehörigen MATLAB-Befehle aufgezeigt. Dabei ist X_1 beispielhaft mit 3 Stützpunkten gewählt, U_1 mit 5 Stützpunkten, X_2 mit 4 Stützpunkten und X_2 mit 2 Stützpunkten. Während bei einer Zustands- und einer Steuergröße eine zweidimensionale Matrix genügt, ist zur Berücksichtigung einer weiteren Zustandsgröße eine dreidimensionale Matrix notwendig. Durch eine zusätzliche Steuergröße steigt die Komplexität auf eine vierdimensionale Matrix an. Dieser Effekt wurde in Kapitel 3.2 auch als Fluch der Dimensionen bzw. die Plage des wachsenden Netzes beschrieben. Für alle Zellen dieser Matrizen werden bei der Rückwärtsrechnung die Kosten C , die unzulässigen Zustände I und die Folgezustände X_{k+1} bestimmt, was zu einem entsprechend hohen Rechenaufwand führt.

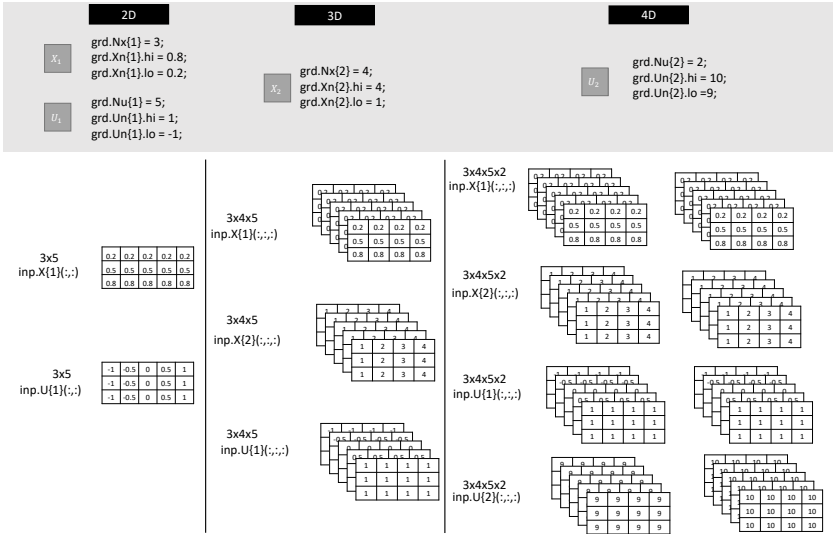


Abbildung B.1: Darstellung der Matrizenarchitektur bei der Rückwärtsrechnung für bis zu zwei Zustands- und Steuergrößen.

C Theoretischer Hintergrund

Pontryagin'sches Minimum-Prinzip und Praxisbeispiel

Ergänzend zu den Ausführungen in Kapitel 3.3 sei an dieser Stelle eine Gesamtübersicht aller notwendigen Bedingungen zur Lösung eines Optimierungsproblems bei HEVs gegeben [Kir70, Gör16, Ono16]. Analog zu Formel 3.11 umfasst die Hamiltonfunktion H in allgemeiner Form die instantanen Kosten L , den Co-State λ_{PMP} und die allgemeine Funktion des Systems f .

$$H(x(t), u(t), \lambda_{PMP}(t), t) = L(x(t), u(t), t) + \lambda_{PMP}(t)^T \cdot f(x(t), u(t), t) \quad (C.1)$$

Dabei formuliert das PMP die folgenden notwendigen Bedingungen für eine optimale Lösung. Die Änderung des Systemzustands ergibt sich aus der allgemeinen Systemfunktion f (in Analogie zu Formel 3.12).

$$\dot{x}^*(t) = f(x^*(t), u^*(t), t) \quad (C.2)$$

Hierbei berechnet sich die Änderungsrate des Co-State λ_{PMP} analog zu Formel 3.14 aus der partiellen Ableitung der instantanen Kosten L und der allgemeinen Systemfunktion f nach dem Systemzustand x .

$$\dot{\lambda}_{PMP}^*(t) = \frac{\partial H}{\partial x} = -\frac{\partial L}{\partial x}(x^*(t), u^*(t), t) - \lambda_{PMP}^*(t) \cdot \left[\frac{\partial f}{\partial x}(x^*(t), u^*(t), t) \right]^T \quad (C.3)$$

Ebenso müssen Start- und Endbedingungen für den Systemzustand x definiert sein.

$$x^*(t_0) = x_0 \quad (\text{C.4})$$

$$x^*(t_f) = x_f \quad (\text{C.5})$$

Dabei muss der optimale Steuergrößenverlauf u^* die Hamiltonfunktion H stets minimieren.

$$H(u(t), x^*(t), \lambda_{PMP}^*(t), t) \geq H(u^*(t), x^*(t), \lambda_{PMP}^*(t), t) \quad (\text{C.6})$$

Man betrachte nun ein einfaches Praxisbeispiel. Dieses soll durch die einfachen Zusammenhänge eine bessere Nachvollziehbarkeit des Funktionsprinzips des PMP ermöglichen und dabei die im Rahmen des Hauptteils der Arbeit angestellten tiefergehenden Untersuchungen untermauern. Die korrekte Abbildung der physikalischen Zusammenhänge liegt demnach nicht im Fokus von Anhang C. Auch eine Interpretation der aufgezeigten Einheiten ist nur teilweise sinnvoll.

Beim Praxisbeispiel wird für einen P1-Hybrid das Drehmoment zwischen den beiden Motoren so aufgeteilt, dass eine vorgegebene Kostenfunktion unter Berücksichtigung eines vorgegebenen Drehmomentverlaufs minimiert wird. Die Fahrgeschwindigkeit bzw. die Drehzahlen der Motoren sind hierbei konstant. Entsprechend Formel C.2 muss das System definiert werden.

$$\dot{x} = f(x, u, T_{req}) \quad (\text{C.7})$$

Dabei repräsentiert x im Praxisbeispiel den Batterieladezustand SOC , u das Drehmoment des Elektromotors T_{EM} in Nm und T_{req} steht für den zeitabhängigen, vorgegebenen Drehmomentverlauf in Nm.

In diesem Fall ist das System durch die Änderungsrate des Batterieladezustands \dot{SOC} in Abhängigkeit des Drehmoments des Elektromotors (Steuergröße u), sowie die Wirkungsgrade von Batterie η_{bat} und Elektromotor (inkl. Leistungselektronik) η_{EM} in Anlehnung an Formel 2.8 definiert. Weiterhin sind die Kurbelwellendrehzahl n_{CS} , die Batteriespannung U_{bat} , sowie die Batteriekapazität C enthalten (siehe Formel C.8).

$$\dot{SOC} = \begin{cases} -\frac{2 \cdot \pi \cdot u \cdot n_{CS}}{60 \frac{s}{min} \cdot \eta_{bat} \cdot \eta_{EM} \cdot U_{bat} \cdot C}, & \text{für } u > 0 \\ -\frac{2 \cdot \pi \cdot u \cdot n_{CS} \cdot \eta_{bat} \cdot \eta_{EM}}{60 \frac{s}{min} \cdot U_{bat} \cdot C}, & \text{für } u \leq 0 \end{cases} \quad (C.8)$$

Im Rahmen des Minimalbeispiels wird davon ausgegangen, dass die konstante Kurbelwellendrehzahl n_{CS} , die ebenso konstante Batteriespannung U_{bat} , sowie die Batteriekapazität C so gewählt sind, dass sich für den Quotient $\frac{2 \cdot \pi \cdot n_{CS}}{60 \frac{s}{min} \cdot U_{bat} \cdot C}$ der Wert 1 ergibt und dieser im weiteren Verlauf zusammengefasst als Batterieladezustandsäquivalenzfaktor $\kappa_{eqv,SOC} = 1 \frac{1}{Nm \cdot s} = 1 \frac{1}{J \cdot s}$ betrachtet werden kann, siehe Formel C.9.

$$\dot{SOC} = \begin{cases} -\frac{u}{\eta_{bat} \cdot \eta_{EM}} \cdot \kappa_{eqv,SOC}, & \text{für } u > 0 \\ -u \cdot \eta_{bat} \cdot \eta_{EM} \cdot \kappa_{eqv,SOC}, & \text{für } u \leq 0 \end{cases} \quad (C.9)$$

Eine exakte Abbildung des realen Betriebsverhaltens des elektrischen Antriebsstrangs bzw. der Wirkungsgrade der Komponenten entsprechend Abbildung 2.5 (EM und LE) und Abbildung 4.1 (BAT) entfällt an dieser Stelle. Für den Wirkungsgrad des Elektromotors (inkl. der Leistungselektronik) wird im Rahmen des Beispiels ein konstanter Wert angenommen ($\eta_{EM}=0.98$). Analog hierzu wird der Batteriewirkungsgrad zunächst konstant angenommen (*Fall 1*). Damit fällt der Wirkungsgrad im motorischen und generatorischen Betrieb gleich aus. Ebenso weist die Batterie sowohl beim Laden wie auch beim Entladen grundsätzlich die gleichen Eigenschaften auf. Zusätzlich wird in einer weiteren Variante zur exemplarischen Abbildung SOC-abhängiger Systemeigenschaften von einer Reduktion des Batteriewirkungsgrades mit dem SOC ausgegangen (*Fall 2*). Entgegen des

typischen Verhaltens von Batterien, bleibt die Batteriespannung U_{bat} dabei stets konstant. Damit ergibt sich entsprechend Formel C.10:

$$\eta_{bat} = \begin{cases} 0.96, & \text{für Fall 1} \\ 0.01 \cdot SOC, & \text{für Fall 2} \end{cases} \quad (C.10)$$

Die Differenz zwischen dem Elektromotordrehmoment u und dem vorgegebenen Drehmoment T_{req} muss von der VKM bzw. der mechanischen Bremse aufgebracht werden. Da das gesamte Fahrprofil mit konstanter Motordrehzahl gefahren wird, ist zur Abbildung der VKM-Charakteristik (vgl. Abbildung 2.4) eine Willans-Linie ausreichend. Hierbei wird der Kraftstoffmassenstrom der VKM für eine konstante Drehzahlen über dem Motordrehmoment aufgetragen. Dabei gibt die Willans-Linie den Kraftstoffbedarf in kg/s an, wobei die Werte auf den Maximalwert normiert sind. Negative Restdrehmomente die sich aus der Differenz zwischen dem Elektromotordrehmoment u und dem vorgegebenen Drehmoment T_{req} ergeben, werden grundsätzlich von der mechanischen Bremse übernommen und verursachen im Rahmen des Minimalbeispiels keine Kosten (siehe Formel C.11).

$$L = \begin{cases} f_{willans}(T_{req} - u), & \text{für } T_{req} - u > 0 \\ 0, & \text{für } T_{req} - u < 0 \end{cases} \quad (C.11)$$

Somit ergibt sich die Hamiltonfunktion analog zu Formel C.1 in diesem Fall zu:

$$H = \begin{cases} L + \lambda_{PMP} \cdot \frac{-u}{\eta_{bat} \cdot \eta_{EM}} \cdot \kappa_{eqv,SOC}, & \text{für } u > 0 \\ L + \lambda_{PMP} \cdot (-u) \cdot \eta_{bat} \cdot \eta_{EM} \cdot \kappa_{eqv,SOC}, & \text{für } u \leq 0 \end{cases} \quad (C.12)$$

Der Gradient der Hamiltonfunktion bezüglich des Batterieladezustands SOC berechnet sich damit nach Formel C.3 unter Berücksichtigung von Formel C.10 und Formel C.12 entsprechend Formel C.13 nach folgendem Zusammenhang (Fall 2):

$$\dot{\lambda}_{PMP} = -\frac{\partial H}{\partial SOC} = \begin{cases} \lambda_{PMP} \cdot \frac{u}{0.01 \cdot SOC^2 \cdot \eta_{EM}} \cdot \kappa_{eqv, SOC}, & \text{für } u > 0 \\ \lambda_{PMP} \cdot (-u) \cdot 0.01 \cdot \eta_{EM} \cdot \kappa_{eqv, SOC}, & \text{für } u \leq 0 \end{cases} \quad (C.13)$$

Für Fall *Fall 1*, also den konstanten Batteriewirkungsgrad ist der Gradient der Hamiltonfunktion stets null.

Als Störgröße wird ein Drehmomentverlauf über 10 s definiert, der Initialzustand der Batterie wird zu $x_0 = 80 \%$ festgelegt und es wird ein ladungserhaltender Betrieb (CS) vorgegeben. Das maximale motorische bzw. generatorische Drehmoment des EM wird durch einen entsprechenden Steuergrößenvektor zu ± 10 Nm festgelegt. Das aus dem vorgegeben Drehmomentenverlauf T_{req} verbleibende Restmoment muss durch die VKM bzw. die mechanische Bremse aufgebracht werden. Ebenso müssen Grenzen für das Schießverfahren bzw. Bisektionsverfahren (vgl. Abbildung 3.3) definiert werden. Damit kann ein beispielhafter Algorithmus implementiert werden, wobei der Code nachfolgend dargestellt ist.

Es werden zwei Fälle simuliert: Im ersten Fall wird ein konstanter Batteriewirkungsgrad angenommen, im zweiten Fall ist der Batteriewirkungsgrad SOC-abhängig. In Abbildung C.1 ist für beide Fälle der vorgegebene Drehmomentenverlauf T_{req} , der Verlauf des Batterieladezustands SOC , der Verlauf des Co-States λ_{PMP} , der Verlauf des Drehmoments des Elektromotors T_{EM} sowie das Restdrehmoment dargestellt, dass durch die VKM bzw. die mechanische Bremse aufgebracht werden muss (T_{ICE} und T_{brake}). Um zu demonstrieren, dass auch zukünftige Rekuperationspotentiale durch das PMP berücksichtigt werden können, wurde der vorgegebene Drehmomentverlauf T_{req} so definiert, dass zunächst ein positives Drehmoment (Traktionsbetrieb) anliegt, und im Anschluss rekuperiert wird. Dabei ist der Drehmomentverlauf so gewählt, dass der Bereich des positiven Drehmoments geringer ist, als der

des negativen Drehmomentes. Für einen konstanten Batteriewirkungsgrad ergibt sich damit ein quasi-symmetrisches Bild beim Elektromotordrehmoment T_{EM} . Durch Aktivieren des SOC-Abhängigen Batteriewirkungsgrades verschlechtert sich der Systemwirkungsgrad insgesamt. Dadurch wird im Bereich des negativen T_{req} weniger Energie rekuperiert und der motorische Betrieb des EM muss eingeschränkt werden, um ladungserhaltenden Betrieb sicherzustellen. Der initiale Wert für den Co-State $\lambda_{PMP,0}$ wurde hierbei jeweils mit dem Schießverfahren bzw. Bisektionsverfahren (vgl. Abbildung 3.3) passend gewählt, sodass die notwendige Bedingung aus Formel C.5 erfüllt wird. Die Gesamtkosten betragen für Fall 1 jeweils $J_{DP}^* = 0.22513$ g und $J_{PMP}^* = 0.22513$ g, sowie für Fall 2 $J_{DP}^* = 0.24715$ g und $J_{PMP}^* = 0.24719$ g. Die Unterschiede der Kosten J zwischen DP- und PMP-Lösung resultieren aus numerischen Fehlern der DP bzw. aus Abweichungen im Endladezustand, der sich für die beiden Verfahren innerhalb der vorgegeben Toleranz unterscheidet.

Analog zu den Ausführungen in Kapitel 3.3 kann anhand dieses einfachen Praxisbeispiels gezeigt werden, dass das PMP auch zukünftig auftretende Rekuperationspotentiale adäquat berücksichtigen kann. Es kann außerdem demonstriert werden, dass auch ein sich mit dem SOC ändernder Batteriewirkungsgrad adäquat vom PMP berücksichtigt werden kann. Es konnte außerdem gezeigt werden, dass bei konstanten Batterieeigenschaften ($\alpha_{bat} = 0$ Nm) auch λ_{PMP} konstant angenommen werden kann.

```

1  clear all; clc; close all
2  %% Parameter und Start- und Endbedingungen
3  T = 10; % Gesamtdauer
4  dt = 0.1; % Zeitschritt
5  N = T / dt; % Anzahl der Zeitschritte
6  u_max = 10; % Maximales Elektromotordrehmoment
7  lambda_lower = -1000; % Untere Schranke für Lambda (Bisektionsverfahren)
8  lambda_upper = 500; % Obere Schranke für Lambda (Bisektionsverfahren)
9  tolerance = 2; % Toleranz für die Endladung (Bisektionsverfahren)
10 N_U = 201; % Anzahl Stützstellen Steuergröße
11 SOC_start = 80; % Startladezustand
12
13 %% Festlegung der Störgröße (Drehmomentprofil)
14 t = linspace(0, T, N+1); % Zeitvektor
15 T_req = 1.2 .* flipplr((t-5.3).^3); % Beispielhaftes Drehmomentprofil
16
17 %% Definition VKM-Kennfeld
18 % Willans-Linie
19 % Kraftstoffbedarf über Drehmomentbedarf (ausgewählte Drehzahl)
20 m_fuel = [0.0706, 0.0950, 0.1195, 0.1428, 0.1658, ...,
21 0.1893, 0.2122, 0.2353, 0.2589, 0.2828, 0.3066, ...,
22 0.3307, 0.3567, 0.3880, 0.4173, 0.4458, 0.4733, ...,
23 0.5027, 0.5367, 0.5763, 0.6228, 0.6840, 0.7714, ...,
24 0.8591, 0.9299, 1.0000]/3600; % /3600 | kg/h auf kg/s
25 % Kraftstoffbedarf in kg/s (normiert auf maximalen angegebenen Wert)
26 T_mfuel = linspace(1,125,26);
27 % Drehmomentstützstellen für Kraftstoffbedarf
28
29 %% Schalter SOC-Abhängige Batterieeigenschaften
30 alpha_bat = 1 ; % 0 // 1
31
32 %% Initialisierung
33 save_cycle_SOC = zeros(1, N);
34 save_cycle_lambda = zeros(1, N);
35 save_cycle_u = zeros(1, N);
36 save_cycle_L = zeros(1, N);
37 %save_cycle_Trq_req = zeros(1, N);
38 save_cycle_SOC(1) = SOC_start;
39
40 %% Main
41 k = 1;
42 while true
43     lambda_start = (lambda_lower + lambda_upper) / 2;
44     for i = 1:N
45         save_cycle_lambda(1) = lambda_start;
46         if i == 1
47             lambda = lambda_start;
48         end
49         u_values = linspace(-u_max, u_max, N_U);
50         % Kostenfunktion
51         L = zeros(size(u_values));
52         % Bestimmung VKM-Kraftstoffbedarf
53         interp_m_fuel = interp1(T_mfuel, m_fuel, T_req(i) - u_values, 'spline');
54         diff = T_req(i) - u_values;
55
56         % Nur VKM-Kosten für positive Werte
57         % Negative Drehmomente über mechanische Bremse
58         L(diff > 0) = interp_m_fuel(diff > 0);
59         % Elektromotor - Wirkungsgrad
60         eta_em = 0.98;
61         % Batteriewirkungsgrad
62         eta_bat = (alpha_bat==1) .* 0.01*(save_cycle_SOC(i)) + (alpha_bat==0) .* 0.96;
63         % Hamiltonfunktion
64         H_val = L + ...
65         (u_values > 0) .* lambda .* (-u_values) ./ eta_bat ./ eta_em + ...
66         (u_values <= 0) .* lambda .* (-u_values) .* eta_bat .* eta_em;
67         % Minimierung

```

```

68     idx_min_H = find(H_val == min(H_val));
69     idx_min_H = idx_min_H(1);
70     min_u = u_values(idx_min_H);
71     min_L = L(idx_min_H);
72     % Neuer Zustand SOC
73     save_cycle_SOC(i+1) = save_cycle_SOC(i) ...
74     + (min_u > 0) .* dt .* (-min_u) ./ eta_bat ./ eta_em + ...
75     + (min_u <= 0) .* dt .* (-min_u) .* eta_bat .* eta_em;
76     % Ableitung Lambda nach Zustand SOC
77     dH_val_pos = (min_u > 0) .* lambda .* min_u ./ (0.01 .* save_cycle_SOC(i).^2 .* eta_em);
78     dH_val_neg = (min_u <= 0) .* lambda .* (-min_u) .* 0.01 .* eta_em;
79     % Bestimmung Ableitung Lambda
80     if alpha_bat == 1
81         lambda_dot = (dH_val_pos + dH_val_neg);
82     else
83         lambda_dot = 0;
84     end
85     % Neues Lambda
86     lambda = lambda + dt * lambda_dot;
87     % Speichere zeitabhängige Werte
88     save_cycle_lambda(i+1) = lambda;
89     save_cycle_u(i+1) = min_u;
90     save_cycle_L(i+1) = min_L;
91     save_cycle_T_rest(i+1) = T_req(i) - min_u;
92     % save_cycle_Trq_req(i+1) = T_req(i);
93 end
94
95 % Speichere Werte für Bisektionsverfahren
96 save_bisektion_soc_end(k) = save_cycle_SOC(end);
97 save_bisektion_lambda_start(k) = lambda_start;
98
99 % Bisektionsverfahren
100 if abs(save_cycle_SOC(end) - SOC_start) < tolerance
101     break;
102 elseif save_cycle_SOC(end) < SOC_start
103     lambda_upper = lambda_start;
104     else
105     lambda_lower = lambda_start;
106     end
107     k = k+1;
108 end

```

Die Untersuchungen werden mittels der *Generic Dynamic Programming-Funktion (dpm-function)* der ETH Zürich bestätigt [Sun09]. Auch hier sind die Einstellparameter und das verwendete Modell angegeben.

Einstellparameter

```

1   grd.Nx{1} = 10000;
2   grd.Xn{1}.hi = 95;
3   grd.Xn{1}.lo = 45;
4   grd.X0{1} = SOC_start;
5   grd.XN{1}.hi = save_cycle_SOC(end) + 0.2;
6   grd.XN{1}.lo = save_cycle_SOC(end) - 0.2;
7   grd.Nu{1} = N_U;
8   grd.Un{1}.hi = u_max;
9   grd.Un{1}.lo = -u_max;
10
11  prb.W{1} = T_req;
12  prb.W{2} = t;
13  prb.Ts = dt;

```

```

14 prb.N = N;
15
16 options = dpm();
17 options.MyInf = 10000000;
18 par.alpha_bat = alpha_bat;
19 par.dt = dt;
20 par.T_mfuel = T_mfuel;
21 par.m_fuel = m_fuel;
22 [res_dyn] = dpm('hev', par, grd, prb, options);

```

Modell

```

1 % Kostenfunktion
2 C{1} = zeros(size(inp.X{1}));
3 % Bestimmung VKM- Kraftstoffbedarf
4 interp_m_fuel = interp1(par.T_mfuel, par.m_fuel, inp.W{1} - inp.U{1}, 'spline');
5 diff = inp.W{1} - inp.U{1};
6 % Nur VKM-Kosten für positive Werte
7 % Negative Drehmomente über mechanische Bremse
8 C{1}(diff > 0) = interp_m_fuel(diff > 0);
9 % Batteriewirkungsgrad
10 eta_bat = (par.alpha_bat==1) .* 0.01*(inp.X{1}) + (par.alpha_bat==0) .* 0.96;
11 % Elektromotor-Wirkungsgrad
12 eta_em = 0.98;
13 % Neuer Zustand SOC
14 X_p = (inp.U{1} > 0).*(-inp.U{1}) ./ eta_bat ./ eta_em ...
15 + (inp.U{1} <= 0).*(-inp.U{1}) .* eta_bat .* eta_em;
16 X{1} = par.dt .* X_p + inp.X{1};
17 % Definition Ausgaben
18 I = zeros(size(X{1}));
19 out.U_1 = inp.U{1};
20 out.T_req = inp.W{1};
21 out.T_rest = inp.W{1} - inp.U{1};;

```




Abbildung C.1: Umsetzung der PMP am einfachen Praxisbeispiel. Die Gesamtkosten betragen für Fall 1 jeweils $J_{DP}^* = 0.22513$ g und $J_{PMP}^* = 0.22513$ g, sowie für Fall 2 $J_{DP}^* = 0.24715$ g und $J_{PMP}^* = 0.24719$ g.

D Simulationsergebnisse: Offline-ECMS und DP

Ergänzend zu Kapitel 4.2 sind nachfolgend die zugrundeliegenden Daten für die angestellten Analysen von DP und Offline-ECMS detailliert für $N_{X_1} = 401$ gelistet. Dies umfasst einen prozentualen Vergleich der CO₂-Emissionen (Tabelle D.1), einen Vergleich der Rechenzeiten (Tabelle D.2) und eine Übersicht über die Differenz des jeweiligen minimalen und maximalen Batterieladezustands $\Delta SOC_{min,max}$ (Tabelle D.3). Der nutzbare Energieinhalt der Batterie beträgt 770 Wh (vgl. Angaben aus Tabelle 4.3).

Tabelle D.1: Prozentualer Vergleich der CO₂-Emissionen über alle zwölf Fahrzyklen zwischen Offline-ECMS und DP. Die prozentualen Abweichungen liegen < 1 %. Realfahrzyklen entsprechend Abbildung 2.7. Die angegebenen CO₂-Emissionen sind auf den höchsten, auftretenden Wert normiert.

Fahrzyklus	P1-Topologie			P2-Topologie			P14-Topologie			P24-Topologie		
	DP	ECMS	Abw.	DP	ECMS	Abw.	DP	ECMS	Abw.	DP	ECMS	Abw.
1	78.72	78.51	0.29	66.12	65.78	0.55	64.36	64.44	-0.18	63.19	63.22	-0.06
2	76.99	76.63	0.43	62.71	62.38	0.5	60.90	60.62	0.39	59.38	59.31	0.1
3	78.47	77.95	0.63	61.14	60.63	0.86	57.31	56.94	0.62	56.38	56.12	0.43
4	61.47	61.40	0.09	53.82	53.75	0.09	54.74	54.82	-0.14	54.53	54.63	-0.2
5	57.87	57.90	-0.06	49.51	49.48	0.05	49.73	49.73	0	49.44	49.49	-0.07
6	59.12	59.20	-0.14	50.78	50.68	0.15	49.91	49.92	-0.02	49.66	49.84	-0.38
7	73.00	73.06	-0.06	68.47	68.42	0.08	74.23	74.38	-0.27	74.18	74.27	-0.15
8	60.75	60.72	0.03	55.02	55.03	-0.01	59.54	59.59	-0.1	59.50	59.47	0.04
9	58.79	58.73	0.09	53.69	53.69	0	58.05	58.21	-0.28	57.99	58.10	-0.18
10	93.40	93.72	-0.35	92.20	92.00	0.19	99.98	100.00	-0.03	99.80	99.66	0.15
11	84.65	84.78	-0.12	83.26	83.12	0.14	88.85	88.93	-0.08	88.58	88.57	0.01
12	78.10	78.16	-0.07	76.66	76.59	0.08	84.53	84.72	-0.21	84.43	84.32	0.12

Tabelle D.2: Vergleich der Rechenzeiten in Minuten über alle zwölf Fahrzyklen zwischen Offline-ECMS und DP. Der Faktor stellt das Verhältnis zwischen der Rechenzeit der DP und der Offline-ECMS dar. Realfahrzyklen entsprechend Abbildung 2.7.

Fahrzyklus	P1-Topologie			P2-Topologie			P14-Topologie			P24-Topologie		
	DP	ECMS	Faktor	DP	ECMS	Faktor	DP	ECMS	Faktor	DP	ECMS	Faktor
1	12.44	3.39	3.67	13.14	2.7	4.87	1099.73	143	76.9	1135.03	19.31	58.78
2	11.94	3.16	3.78	12.27	3.05	4.02	855.34	12.71	67.3	902.03	11.75	76.77
3	10.61	2.75	3.86	10.91	3.47	3.14	799.66	13.64	58.63	839.78	12.17	69
4	29.25	8.61	3.4	30.08	10.83	2.78	2597.3	28.89	89.9	2669.2	29.65	90.02
5	34.93	11.18	3.12	35.32	12.29	2.89	2271.42	36.62	62.03	2283.94	38.62	59.14
6	25.39	7.87	3.23	25.84	9.6	2.69	1993.1	31.49	63.29	1733.83	20.11	86.22
7	26.02	6.35	4.1	26.63	7.04	3.78	2264.28	31.21	72.55	2317.96	28.62	80.99
8	34.04	10.56	3.22	34.49	10.19	3.38	2293.57	26.61	86.19	2184.81	27.58	79.22
9	17.98	6.13	2.93	18.7	4.24	4.41	1404.44	17.33	81.04	1446	19.83	72.92
10	39.5	6.52	6.06	42.85	9.48	4.52	3649.97	34.2	106.72	3464.93	36.63	94.59
11	18.65	4.11	4.54	19.38	4.67	4.15	1529.19	19.34	79.07	1564.18	15.21	102.84
12	23.2	5.81	3.99	24.11	6.44	3.74	1855.62	12.22	151.85	1618.98	9.29	174.27

In der nachfolgenden Tabelle sind die in der DP und der Offline-ECMS jeweils erreichten Differenzen zwischen maximalem und minimalem Ladezustand ($\Delta SOC_{min,max}$) entsprechend Formel 5.3 für jeden betrachteten Fahrzyklus aufgelistet. Da DP und Offline-ECMS grundsätzlich verschiedene Herangehensweisen zur Bestimmung der CO_2 -optimalen Lösung verfolgen (vgl. Kapitel 3.2 und Kapitel 3.3), besitzen auch die SOC-Trajektorien teilweise unterschiedliche Werte für $\Delta SOC_{min,max}$, obwohl diese zu den annähernd gleichen CO_2 -Emissionen führen (vgl. Tabelle D.1). Es ist deutlich zu erkennen, dass für die Fahrzyklen 1-3 (Stadtfahrten mit insgesamt geringer Dynamik, siehe Abbildung 2.7) die CO_2 -optimale Lösung über alle Topologien einen - im Vergleich zu den übrigen Fahrzyklen - kleinen Wert für $\Delta SOC_{min,max}$ aufweist, und X_1 entsprechend den allgemeinen Empfehlungen zur Anwendung der DP aus Kapitel 4.2.2 besonders fein diskretisiert werden sollte.

Tabelle D.3: Vergleich von $\Delta SOC_{min,max}$ über alle zwölf Realfahrzyklen zwischen Offline-ECMS und DP. Realfahrzyklen entsprechend Abbildung 2.7.

Fahrzyklus	P1-Topologie		P2-Topologie		P14-Topologie		P24-Topol.	
	DP	ECMS	DP	ECMS	DP	ECMS	DP	ECMS
1	0.44	0.45	0.44	0.45	0.65	0.62	0.69	0.59
2	0.43	0.41	0.48	0.48	0.53	0.54	0.57	0.56
3	0.52	0.51	0.5	0.49	0.43	0.39	0.5	0.4
4	1.2	1.17	1.25	1.25	1.99	1.89	1.95	1.89
5	1.18	1.17	1.38	1.3	1.98	1.89	1.97	1.88
6	1	1.06	0.93	0.92	2.2	2.15	2.35	2.29
7	2.17	2.19	1.34	1.31	1.44	1.56	1.44	1.53
8	2.32	2.21	2.28	2.12	2.63	2.57	2.65	2.57
9	1.72	1.73	1.1	1.13	1.28	1.38	1.26	1.29
10	3.53	4.14	3.44	3.73	3.62	3.6	3.7	3.82
11	2.47	2.84	1.15	1.2	1.92	1.72	1.62	1.51
12	2.12	1.92	1.48	1.73	2.01	1.95	1.79	1.71

Ergänzend zu Abbildung 4.6 sind in Abbildung D.1 die ausgewählten physikalischen Größen zusätzlich im Zeitbereich für den exemplarisch herangezogenen Fahrzyklus dargestellt. Auch hier ergibt sich eine gute Übereinstimmung. Dies deckt sich mit dem jeweils hohen Bestimmtheitsmaß R^2 in Abbildung 4.6.




Abbildung D.1: Visualisierung ausgewählter physikalischer Größen zur Validierung des DP-Modells über der Zeit mittels des bestehenden ECMS-Modells, P2 (oben) und P24 (unten) für $N_{X_1} = 401$ im Realfahrzyklus *urban low mild* (Realfahrzyklus Nr. 3 aus Abbildung 2.7). Die Lösung der DP ist jeweils mittels der blauen Kurve dargestellt. Die Lösung der Offline-ECMS ist über die orangene Kurve gegeben.

E Zielkonflikt Fahrkomfort (VKM-Starts) gegenüber CO₂: ECMS und DP

Ergänzend zu Kapitel 4.3.1 sind nachfolgend weitere Ergebnisse zum Zielkonflikt Fahrkomfort (repräsentiert durch VKM-Starts) gegenüber CO₂-Emissionen für die Offline-ECMS und die DP aufgezeigt. Wie erwähnt, wird in [För24] die Berücksichtigung des Start/Stopp-Verhaltens der VKM durch die Einführung einer weiteren Zustandsgröße im Rahmen der Offline-ECMS verbessert ($E_{stp,hyst}$). Dabei wird die zusätzliche Energie, welche im Vergleich zur Lösung ohne Bestrafung der VKM-Starts für die Vermeidung eines Zustandswechsels notwendig ist, über eine weitere Zustandsgröße integriert. Ist eine festgelegte Schwelle $E_{stp,hyst,max}$ überschritten, wird die Erhöhung des Äquivalenzverbrauchs im Optimierungsproblem nach Formel 3.18 ausgesetzt und $E_{stp,hyst}$ auf Null gesetzt. Durch diesen zusätzlichen Parameter kann der in Abbildung 4.9 gezeigte Zielkonflikt besser gelöst werden (rote Kreuze in Abbildung E.1). Die optimale EMS aus der DP kann jedoch auch mit dieser zusätzlichen Zustandsgröße nicht gefunden werden.




Abbildung E.1: Zielkonflikt CO₂-Einsparpotential und Fahrkomfort, repräsentiert durch VKM-Starts beim Realfahrzyklus *urban low mild* (Realfahrzyklus Nr. 3 aus Abbildung 2.7) für eine P2-Topologie mit Hysterese $E_{stsp,hyst}$.

F Ergänzende Informationen zur Online-ECMS

Ergänzend zu Kapitel 5.1 sind nachfolgend weitere Informationen zur Auslegung der Online-ECMS beschrieben.

Bestimmung $\lambda_{0,avg}$

Nachfolgend sind die aus der Offline-ECMS über alle zwölf Fahrzyklen ermittelten λ_0 -Werte aus Abbildung 5.2 dargestellt. Diese dienen als Basis für den $\lambda_{0,avg}$ -Wert der Online-ECMS (Tabelle F.1).







Tabelle F.1: Vergleich der Äquivalenzfaktoren λ_0 aus der Offline-ECMS zur Bestimmung von $\lambda_{0,avg}$ für die Online-ECMS. Realfahrzyklen entsprechend Abbildung 2.7.




Fahrzyklus	Topologien			
	P1	P2	P14	P24
1	2.48	2.80	2.98	2.99
2	2.48	2.89	3.04	3.05
3	2.52	3.00	3.18	3.18
4	2.48	2.95	3.16	3.16
5	2.48	2.96	3.20	3.20
6	2.46	2.99	3.23	3.23
7	2.55	2.84	3.11	3.11
8	2.48	2.77	3.02	3.02
9	2.51	2.81	3.05	3.04
10	2.75	2.94	3.13	3.14
11	2.69	2.91	3.05	3.06
12	2.72	2.92	3.13	3.13

Bestimmung kp_{SOC}

Nachdem die Bestimmung des kp_{SOC} -Werts für die P1-Topologie bereits in Kapitel 5.1.2 diskutiert wurde, ist im Folgenden die Ermittlung des kp_{SOC} -Wertes über alle Fahrzyklen für die P2-Topologie (Abbildungen F.1-F.3), die P14-Topologie (Abbildungen F.4-F.6) und die P24-Topologie (Abbildungen F.7-F.9) aufgezeigt. Dargestellt sind weiterhin die Fahrzyklen aus Abbildung 2.7. Die Anordnung der zwölf Zyklen ist analog zu Kapitel 5.1.2, aus Platzgründen wird an dieser Stelle auf eine Nummerierung verzichtet. Insgesamt zeigt sich über alle Fahrzyklen die erwartete Zunahme der CO_2 -Emissionen bei gleichzeitiger Verringerung der Differenz zwischen maximalem und minimalem Ladezustand ($\Delta SOC_{min,max}$). Ebenso konvergieren die $\Delta E_{CS,end}$ -Verläufe für fast alle Topologien mit zunehmendem kp_{SOC} zu der Batterieladung, die sich ausgehend vom Initialladezustand mit der recuperierten Energie der Schlussbremsung ergibt. Grund hierfür ist, dass eine Ladung der Batterie im Rekuperationsfall auch bei sehr hohen Werten für kp_{SOC} stets zugelassen wird (vgl. Kapitel 5.1.2). Vereinzelt ist eine Abnahme in den CO_2 -Emissionen mit zunehmendem kp_{SOC} wahrzunehmen. Dies lässt sich wie folgt erklären: Bei großen Abweichungen des gewählten $\lambda_{0,avg}$ zum individuell passenden λ_0 der Offline-Lösung und gleichzeitig geringen Werten für kp_{SOC} kommt es zu einer großen Differenz des Endladezustands von der Initialladung. Die berechneten CO_2 -Emissionen müssen hier besonders stark entsprechend Formel 5.15 korrigiert werden, um eine Vergleichbarkeit der simulierten CO_2 -Emissionen zu ermöglichen. Da diese Korrektur basierend auf gemittelten Wirkungsgraden erfolgt, kann es zu einer Überkompensation der eigentlichen Trends durch entsprechende Ungenauigkeiten kommen.

Darüber hinaus sind in Tabelle F.2 die in Abbildung 5.7 dargestellten Abweichungen der entwickelten Online-ECMS zum globalen Optimum hinsichtlich CO_2 -Emissionen für alle untersuchten Topologien tabellarisch gelistet.

Bestimmung kp_{SOC} für P2**Abbildung F.1:** CO_2 über kp_{SOC} (P2).**Bestimmung kp_{SOC} für P14****Abbildung F.4:** CO_2 über kp_{SOC} (P14).**Abbildung F.2:** $\Delta SOC_{min,max}$ über kp_{SOC} (P2).**Abbildung F.5:** $\Delta SOC_{min,max}$ über kp_{SOC} (P14).**Abbildung F.3:** $\Delta E_{CS,end}$ über kp_{SOC} (P2).**Abbildung F.6:** $\Delta E_{CS,end}$ über kp_{SOC} (P14).

Bestimmung kp_{SOC} für P24Abbildung F.7: CO_2 über kp_{SOC} (P24).Abbildung F.8: $\Delta SOC_{min,max}$ über kp_{SOC} (P24).Abbildung F.9: $\Delta E_{CS,end}$ über kp_{SOC} (P24).Tabelle F.2: Ergebnisse Online-ECMS für P1, P2, P14, P24. Realfahrzyklen entsprechend Abbildung 2.7. Die angegebenen CO_2 -Emissionen sind auf den höchsten, auftretenden Wert normiert.

Fahrzyklus	P1-Topologie		P2-Topologie		P14-Topologie		P24-Topologie	
	Offline	Abw. %	Offline	Abw. %	Offline	Abw. %	Offline	Abw. %
1	7803	0.11	6535	-0.76	6500	-1.46	6285	-1.59
2	7616	0.36	6205	-0.42	6114	-1.44	5898	-1.53
3	7748	0.05	6026	-0.73	5700	-0.76	5580	-0.68
4	7703	0.05	5342	-0.39	5445	-0.88	5431	-0.99
5	5713	0.05	4916	-0.39	4908	-0.12	4889	-1.09
6	5884	0.38	5036	-0.41	5009	-0.96	4954	-0.78
7	7261	-0.13	6801	-0.40	7394	-0.60	7383	-0.63
8	6033	-0.20	5513	-0.88	5923	-1.57	5910	-1.51
9	5837	-0.29	5382	-0.88	5853	-1.24	5773	-1.34
10	5837	-0.29	5382	-0.88	5853	-1.24	5773	-1.34
11	8423	-0.05	8262	-0.28	8838	-0.56	8850	-0.54
12	7769	-0.21	7641	-0.40	8448	-0.38	8380	-0.65

G Dauerläuferdaten zur Validierung der Online-ECMS

Ergänzend zu den Ausführungen aus Kapitel 5.2 werden an dieser Stelle weiterführende Informationen zum verwendeten *Datensatz zur Validierung* dargestellt.

Vorhandene Messsignale aus Messungen

Nachfolgend sind alle Messsignale gelistet, die zur Validierung der entwickelten Online-ECMS herangezogen werden.

- Fahrzyklus
 - Fahrzeuggeschw.
 - Fahrbahnsteigung
 - Lufttemperatur
- 48 V-Elektromotor
 - Strom
 - Spannung
 - Drehmoment
- Räder und Getriebe
 - Raddrehzahl
 - Gang
 - Gangübersetzung
- 48 V-Batterie
 - Ladezustand SOC
 - Spannung
 - Strom
 - Temperatur
- Verbrennungskraftmaschine
 - Drehzahl
 - Drehmoment
 - Status (Leerlauf, Normalbetrieb,...)
 - Kraftstoffvolumenstrom

Längsdynamikmodell

Entsprechend den in Kapitel 5.2.2 definierten Gütekriterien sind nachfolgend für die verwendeten 34 Realfahrzyklen die RMSE-Werte zwischen gemessener und im Modell berechneter Kurbelwellenleistung P_{CS} für eine Variation der Masse, des Roll- und des Luftwiderstandsbeiwerts visualisiert (Abbildung G.1). Aufgetragen ist der RMSE der Kurbelwellenleistung P_{CS} über dem jeweiligen Korrekturfaktor. Hierbei werden spezifisch die drei in Kapitel 5.2.2 definierten Kategorien zur Identifikation der jeweils relevanten Segmente aus den Fahrzyklen verwendet. Die Ergebnisse für die 34 Fahrzyklen sind jeweils in grau eingezeichnet, die gemittelten Werte in schwarz.




Abbildung G.1: Parameterstudien zur Korrektur des Masse und des Roll- bzw. Luftwiderstandsbeiwerts. Dargestellt ist die Abweichung zwischen Simulations- und Messergebnis als RMSE der Kurbelwellenleistung. Fahrzyklen aus Messung entsprechend Abbildung 5.10 (Datensatz zur Validierung).

Für den Rollwiderstand ist aufgrund der wechselnden Fahrbahnbeläge kein eindeutiger Trend erkennbar. Für das Produkt aus Luftwiderstandsbeiwert und Querschnittsfläche sind keine Anpassungen notwendig; ein Korrekturwert von 1 liefert den geringsten RMSE-Wert. Bei der Masse ergibt sich der geringste Fehler über alle Fahrzyklen mit einem Korrekturfaktor von 1.2. Eine Analyse der übrigen Gütekriterien führt zu äquivalenten Ergebnissen. Im Hauptteil der Arbeit sind die Ergebnisse aller vier Gütekriterien aus Kapitel 5.2.2 für die Masse dargestellt (Abbildung 5.13).

Getriebe

Wie in Kapitel 5.2.2 gezeigt kann die Gangwahl im Modell durch Einführung eines Korrekturfaktors an die Messung angepasst werden. Die Auswirkung auf das bereits im Rahmen der Modellierung in Abbildung 2.3 eingeführte Kennfeld zur Schaltlogik sind nachfolgend dargestellt. Zur besseren Visualisierung wird hier eine zweidimensionale Ansicht gewählt (Abbildung G.2). Dabei sind weiterhin die Hochschaltlinien für die verschiedenen Gänge in Abhängigkeit der Hochschaltgeschwindigkeit $v_{upshift}$ und der Fahrpedalstellung App aufgetragen.




Abbildung G.2: Auswirkung des Getriebekorrekturfaktors auf das Kennfeld.

Für den Fall einer Fahrt mit 220 km/h wird ohne Korrekturen beispielsweise ein Hochschalten vom 8. Gang in den 9. Gang initiiert, wenn die Last unter 53 % fällt. Mit Korrekturfaktor wird erst dann ein Hochschalten eingeleitet, wenn die Last unter 18 % fällt.

Verbrennungsmotor

Der gemessene Kraftstoffbedarf wird mit dem sich für die gemessenen VKM-Drehzahlen und -Drehmomente ergebenden Kraftstoffbedarf aus den hinterlegten Kennfeldern im Modell abgeglichen. Letzteres lässt sich als Simulation der EMS des Testfahrzeugs im VKM-Modell interpretieren. In Abbildung G.3

sind hierzu die Abweichungen der gemessenen CO_2 -Emissionen gegenüber den CO_2 -Emissionen aus dem VKM-Kennfeld über alle Fahrzyklen aus dem Datensatz zur Validierung aufgetragen. Es zeigt sich, dass die gemessenen Kraftstoffverbräuche für die gleichen VKM-Betriebspunkte 3-15 % höher ausfallen.




Abbildung G.3: Prozentuale Abweichung der im VKM-Kennfeld simulierten Betriebspunkte aus der Messung gegenüber dem tatsächlich gemessenen Kraftstoffverbrauch. Fahrzyklen aus Messung entsprechend Abbildung 5.10 (Datensatz zur Validierung).

Für Absolutbetrachtungen hinsichtlich zusätzlicher CO_2 -Einsparpotentiale werden daher stets die Verbräuche aus dem hinterlegten Wirkungsgrad-kennfeld herangezogen.

Nebenverbraucher

Die beschriebene Methodik zur Ermittlung der Nebenverbraucherleistungen wird anhand der gemessenen Lufttemperaturen (Außentemperaturen) validiert. Dafür sind in Abbildung G.4 (links) die Temperaturen $\theta_{outside}$ über der Zeit für alle Validierungsmessungen dargestellt. Die Außentemperaturen über die verschiedenen Messungen schwanken zwischen 0 °C und 45 °C. Rechts sind zusätzlich die mittleren NV-Leistungen $P_{aux,avg}$ über der gemittelten Außentemperatur $\theta_{outside,avg}$ aufgetragen. $P_{aux,avg}$ wurde dabei mittels des 4-Quadranten Verfahrens aus Kapitel 5.2.2 ermittelt.




Abbildung G.4: Verläufe der Außentemperatur im jeweiligen Fahrzyklus über der Zeit (links). Durchschnittliche Nebenverbraucherleistung in Abhängigkeit der Außentemperatur (rechts). Dargestellt jeweils für die Fahrzyklen aus der Messung entsprechend Abbildung 5.10 (Datensatz zur Validierung).

Üblicherweise ist die Temperatur bei den Testfahrzeugen auf 22 $^{\circ}\text{C}$ gestellt. Bis zu dieser Temperatur liegen die mittels des entwickelten 4-Quadranten-Verfahrens bestimmten, mittleren NV-Leistungen $P_{aux,avg}$ bei maximal 1,6 kW. Unterhalb von 22 $^{\circ}\text{C}$ kann die Temperatur durch die Abwärme des Motors ohne zusätzlichen elektrischen Energieaufwand gestellt werden, obgleich durch Sonneneinstrahlung und variierende Abwärme der Testfahrer, auch Eingriffe bei geringeren Temperaturen möglich sind. Für Temperaturen größer 22 $^{\circ}\text{C}$ ist ein signifikanter Zuwachs der Nebenverbraucherleistung $P_{aux,avg}$ durch den Klimakompressor festzustellen (bis zu 2,8 kW). Insgesamt liefert das entwickelte 4-Quadranten Verfahren plausible Ergebnisse.

Rekuperationsverhalten

In Abbildung G.5 wird die rekuperierte Leistung der optimalen EMS im Modell (blaue Kurve) mit der rekuperierten Leistung aus der Messung (orangene Kurve) verglichen. Dabei sind jeweils die rekuperierten Leistungen am EM (P_{EM}) für einen ausgewählten Zeitabschnitt dargestellt. Obwohl in der Messung des Testfahrzeugs teilweise höhere Leistungen rekuperiert werden können als im Modell, zeigt sich in der Messung insgesamt ein deutlich konservativeres Eingreifen des EM um negative Drehmomente zu rekuperieren.

Es kommt zu einem entsprechend häufigen Einsatz der mechanischen Bremse (nicht dargestellt).




Abbildung G.5: Rekuperationsverhalten der optimalen EMS im Modell gegenüber der Messung im Realbetrieb. Dargestellt für einen exemplarischen Fahrzyklus aus Abbildung 5.10 (Datensatz zur Validierung).

Die rekuperierte Energie im Modell ist insgesamt höher als im Testfahrzeug (Kapitel 5.2.3).

H Übersicht alternative Realfahrdaten

Der in Kapitel 2.3.2 bzw. Kapitel 6 genannte *Alternative Datensatz* umfasst insgesamt vier Testfahrer. Die wichtigsten Kennzahlen für die vier Fahrer sind in Tabelle H.1 und Abbildung H.1 dargestellt. Dabei gibt t_{total} die Gesamtdauer des jeweiligen Datensatzes an und d_{total} die Gesamtdistanz. $\tau_{standstill}$ gibt den jeweiligen Standzeitanteil an und v_{max} die Maximalgeschwindigkeit. a_{max} gibt die maximale Fahrzeugbeschleunigung an, a_{min} die minimale Fahrzeugbeschleunigung. α_{max} steht für die maximale Fahrbahnsteigung, α_{min} hingegen für die minimale Fahrbahnsteigung. RMS_v , RMS_a und RMS_α repräsentieren jeweils den Effektivwert von Fahrzeuggeschwindigkeit, Fahrzeugbeschleunigung und Fahrbahnsteigung.

Tabelle H.1: Alternativer Datensatz zur Untersuchung prädiktiver EMS. Aus Deufel et al. [1].

		Fahrer 1	Fahrer 2	Fahrer 3	Fahrer 4
τ_{total}	h	31.34	10.83	8.24	9.73
d_{total}	km	2825.49	564.49	590.28	500.68
$\tau_{standstill}$	$\%$	7.29	14.82	6.76	10.17
v_{max}	km/h	191.90	155.79	138.76	109.26
a_{max}	m/s^2	1.83	1.57	1.54	1.45
a_{min}	m/s^2	-2.11	-1.92	-1.75	-1.72
α_{max}	$\%$	15.44	11.62	11.52	1.63
α_{min}	$\%$	-16.10	-12.47	-11.58	-1.52
RMS_v	km/h	100.24	61.71	80.68	59.54
RMS_a	m/s^2	0.32	0.39	0.36	0.37
RMS_α	$\%$	2.85	2.73	1.74	0.55

Grundsätzlich hat Fahrer 1 die höchste Distanz zurückgelegt und weist ebenso die höchste Fahrdauer auf. Sowohl die Maximalgeschwindigkeiten als auch

die Maximalbeschleunigungen und -verzögerungen erreichen hier die größten Werte. Im Durchschnitt treten jedoch geringe Fahrzeugbeschleunigungen auf, wie der niedrigste RMS_a (Root Mean Squared) Wert zeigt. Dies zeigt sich auch im v-a-Diagramm in Abbildung H.1. Daraus lässt sich schließen, dass Fahrer 1 überwiegend auf der Autobahn fährt (vgl. Deufel et al. [1]).




Abbildung H.1: Verteilung von Fahrzeuggeschwindigkeit, Fahrzeugbeschleunigung und Fahrbahnsteigung des Alternativen Datensatzes. Aus Deufel et al. [1].

Fahrer 2 zeichnet sich durch den höchsten Anteil an Stillstandszeiten und den höchsten Wert der durchschnittlich auftretenden Fahrzeugbeschleunigung aus. Wie aus dem v-a-Diagramm hervorgeht, fährt Fahrer 2 hauptsächlich in der Stadt und gelegentlich auf Landstraßen. Wie ebenfalls in Abbildung H.1 zu sehen, bewegt sich Fahrer 3 primär in der Stadt oder auf der Autobahn mit einer konstanten Fahrzeuggeschwindigkeit von 120 km/h. Die Fahrten von Fahrer 4 haben ebenfalls einen hohen Anteil an geringer Fahrzeugbeschleunigung auf Landstraßen im Fahrzeuggeschwindigkeitsbereich

von 80-100 km/h. Was die gefahrenen Fahrbahnsteigungen betrifft, so befährt Fahrer 4 Straßen mit auffallend geringer Fahrbahnsteigung. Die von Fahrer 1-3 befahrene Straßen verfügen über eine ähnliche Verteilung der auftretenden Fahrbahnsteigung ($\pm 5\%$), siehe auch Deufel et al. [1].

I **Praxisbeispiel: Aufbereitung von Realfahrdaten**

In Anhang H wurde bereits der *Alternative Datensatz* bestehend aus Realfahrzyklen mit einer Gesamtdistanz von rund 4500 km vorgestellt. Er umfasst vier verschiedene Fahrer und deckt das gesamte Spektrum von Stadtfahrten über Landstraßenfahrten bis hin zu Autobahnfahrten ab. Um mit den aufgezeichneten GNSS-Tracks die im Hauptteil der Arbeit beschriebenen Untersuchungen durchführen zu können, müssen diese zunächst aufbereitet werden. Dabei werden zum einen die notwendigen Geschwindigkeits- und Steigungsprofile errechnet, zum anderen werden die Fahrprofile zusätzlich um Karteninformationen wie Kurven, Ampeln sowie weitere Verkehrszeichen angereichert. Anschließend kann der *Alternative Datensatz* analog zu den zwölf Realfahrzyklen (Abbildung 2.7) und den Fahrten aus dem *Datensatz zur Validierung* (Abbildung 5.10) im Simulationsmodell verwendet werden. Die Daten wurden mit einer Abtastrate von 1 s aufgezeichnet, wobei in Abbildung I.1 ein beispielhafter Fahrzyklus zu sehen ist. Eine Verringerung der Fahrzeuggeschwindigkeit, z. B. in einer Kurve, führt dazu, dass sich die Trackingpunkte deutlich annähern (vgl. Deufel et al. [3]).

Die nachfolgend beschriebene Methodik zur Aufbereitung der Realfahrten wurde im Wesentlichen durch [S3] entwickelt und in Deufel et al. [3] veröffentlicht.

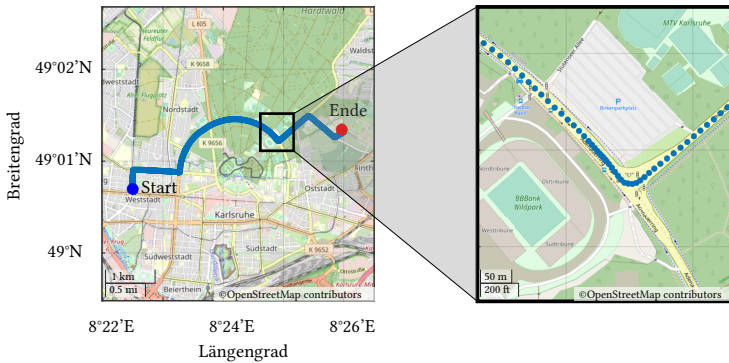


Abbildung I.1: Visualisierung der verfügbaren Fahrdaten aus dem *Alternativen Datensatz*. Aus Deufel et al. [3].

Abgleich mit SRTM- und OSM-Datenbank

In einem ersten Schritt werden relevante OpenStreetMap (OSM)-Daten von der Geofabrik [Geo23] heruntergeladen. Nach der Datenreduzierung mit Osmosis [Mig23] wird ein weiteres Preprocessing mit zwei MATLAB-Funktionen namens *xml2struct* [Fal23] und *parse_openstreetmap* [Fil23] durchgeführt. Damit ergeben sich zwei MATLAB-*structs* (vgl. Deufel et al. [3]).

- Das eine *struct* enthält Knoten. Knoten sind *Points of Interest*, die durch ihre Koordinaten, die spezifischen Attribute des Knotens (z. B. ob eine Ampel vorhanden ist) und eine individuelle Kennzeichnung (ID) definiert sind (vgl. Deufel et al. [3]).
- Knoten werden außerdem sogenannten *ways* zugeordnet, welche das zweite *struct* darstellen. *Ways* können als Straßen interpretiert werden, die auch spezifische Attribute haben können, wie z. B. die zulässige Höchstgeschwindigkeit (vgl. Deufel et al. [3]).

Zusätzlich werden Höhendaten von der *Shuttle Radar Topography Mission* (SRTM) von [USG23] heruntergeladen. Die SRTM-Daten sind in Abbildung I.2 beispielhaft visualisiert, wobei die Alpen gut sichtbar sind. Des Weiteren sind

z. B. die Höhenlage um Venedig auf Meereshöhe (12°E, 45°N) und die Schwäbische Alb, auf einer Höhe von ca. 800 m bei 9.5°E, 48.5°N deutlich zu erkennen (vgl. Deufel et al. [3]).

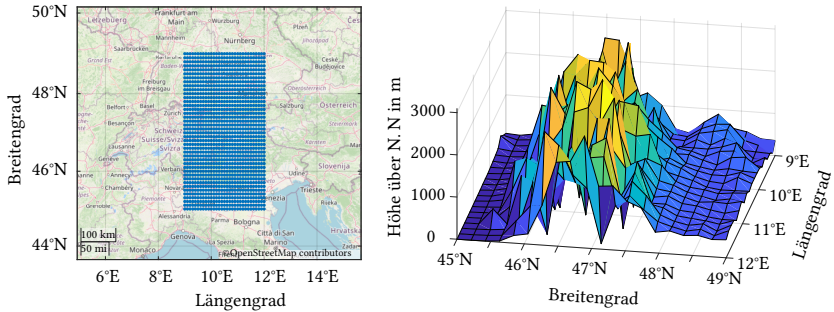


Abbildung I.2: Visualisierung von SRTM-Datenpunkten in der Karte (links) und entsprechende Höhendaten (rechts) aus Deufel et al. [3].

Während die Anreicherung mit SRTM-Höhendaten durch eine einfache 2D-Interpolation erreicht wird, liegt eine Herausforderung im effizienten Abgleich der GNSS-Tracks mit den relevanten Daten aus den OSM-Strukturen. Hierfür wird die datengetriebene Methode *KDTreeSearcher* aus MATLAB verwendet. In Abbildung I.3 ist exemplarisch die bereits in Abbildung I.1 dargestellte Route einschließlich der vom entwickelten Matching-Algorithmus berücksichtigten Straßen (schwarze Linien) eingezeichnet. Darüber hinaus sind die identifizierten Knotenpunkte von Ampeln (grüne Punkte), Vorfahrt Gewähren (blaue Punkte) und Stop (schwarze Punkte) eingetragen (vgl. Deufel et al. [3]).




Abbildung I.3: Visualisierung der identifizierten OSM-Daten einschließlich GNSS-Track, Ampel, Vorfahrt gewähren und Stop. Außerdem wird die zulässige Höchstgeschwindigkeit korrekt erkannt, auch wenn sie richtungsabhängig ist (nicht dargestellt). Aus Deufel et al. [3].

Bestimmung der Fahrzeuggeschwindigkeit

Um eine robuste Fahrzeuggeschwindigkeitsberechnung aus den GNSS-Tracks zu gewährleisten, wird eine zweistufige Filtermethodik entwickelt. Die Auswirkungen sind in Abbildung I.4 dargestellt. Hier sind die Geschwindigkeitsverläufe für eine beispielhafte Sequenz aufgezeigt (vgl. Deufel et al. [3]).

- Im ersten Schritt werden auf Basis von [Bur09], eine maximale Fahrzeugbeschleunigung und Abbremsung in Abhängigkeit von der Fahrzeuggeschwindigkeit in einer Lookup-Tabelle hinterlegt. Dies erfolgt für jedes Testfahrzeug individuell. Fehlerhafte Messungen, die durch einen Sprung im GNSS-Signal (*Rohdaten*) entstanden sind, werden dann durch eine lineare Interpolation zwischen dem ersten und dem letzten gültigen Datenpunkt überschrieben (*Filter 1*).
- Im zweiten Schritt wird ein Tiefpassfilter verwendet, um das endgültige Signal (*Finales Signal*) zu berechnen.
- Abgebildet ist zudem eine Referenzgeschwindigkeit, welche durch ein alternatives Verfahren bestimmt wurde und zur Plausibilisierung dient.

Wie in der Abbildung zu sehen ist, können offensichtliche Ausreißer mit dem ersten Filter gut korrigiert werden (siehe *Filter 1*). Eine Anwendung des Tiefpassfilters sorgt für eine weitere Glättung (siehe *Finales Signal*). Die Sequenz zeigt jedoch deutlich, dass auch das Referenzsignal fehlerbehaftet ist (vgl. Deufel et al. [3]).




Abbildung I.4: Visualisierung der zweistufigen Filtermethode zur Fahrzeuggeschwindigkeitsberechnung anhand einer beispielhaften Sequenz. Aus Deufel et al. [3].

Bestimmung von Kurven

In den letzten Jahren wurden verschiedene Ansätze zur Berechnung der Krümmung ausgearbeitet. So kann beispielsweise angenommen werden, dass sich das Fahrzeug zwischen drei Punkten des GNSS-Tracks auf einem Kreisabschnitt bewegt. Wenn die Koordinaten zum aktuellen Zeitpunkt, zum Zeitpunkt t_{k-1} und zum Zeitpunkt t_{k+1} bekannt sind, kann der Radius des angenommenen Kreises zum Zeitpunkt t_k berechnet werden. Die Ergebnisse dieses einfachen geometrischen Ansatzes sind jedoch aufgrund von Ungenauigkeiten bei den GNSS-Messungen nicht zufriedenstellend. Um eine robuste Nutzung zu gewährleisten, wird eine weitere zweistufige Filtermethode entwickelt (vgl. Deufel et al. [3]):

- Im ersten Schritt wird der GNSS-Track mit Hilfe von *smoothPathSpline* aus der *MATLAB Automated Driving Toolbox* aufbereitet, wobei der GNSS-Track mittels kubischer Spline-Interpolation geglättet wird.
- Im zweiten Schritt wird die Peilung ϕ zu einer bestimmten Achse für jeden Zeitschritt bestimmt, die schließlich durch einen Tiefpassfilter gefiltert wird.

Anschließend wird die Krümmung mit $\kappa = \frac{d\phi}{ds}$ berechnet, wobei $d\phi$ die Änderung der Peilung zur angegebenen Achse darstellt und ds für den entsprechenden Streckenabschnitt steht (vgl. Deufel et al. [3]).

Nachfolgend wird der Algorithmus auf den beispielhaften Fahrzyklus angewendet, der bereits in Abbildung I.1 dargestellt wurde. In Abbildung I.5 sind sowohl die Rohdaten als auch die geglätteten Daten unter Anwendung von *smoothPathSpline* zu sehen. Zusätzlich ist der approximierte Kreis eingetragen, der sich durch eine Approximation aus den geometrischen Verhältnissen ergibt (vgl. Deufel et al. [3]).




Abbildung 1.5: Rohdaten aus dem GNSS-Track aus I.1 (blau) sowie die geglätteten Daten (orange). Zusätzlich ist der approximierte Kreis eingezeichnet (grau) sowie der zugehörige Radius des Adenauerrings in Karlsruhe aus der Geometrie. Aus Deufel et al. [3].

In Abbildung I.6 ist die berechnete Peilung ϕ sowohl mit (schwarze Linie) als auch ohne Tiefpassfilter (gestrichelte Linie) über der Distanz d aufgetragen. Außerdem sind die berechneten Krümmungen κ dargestellt (rote Linie).




Abbildung 1.6: Visualisierung der berechneten Peilung und Krümmung unter Verwendung des Tiefpassfilters für den GNSS-Track aus I.1. Aus Deufel et al. [3].

Zur Validierung wird der Radius des Adenauerrings in Karlsruhe mithilfe des Algorithmus bestimmt. Aus der Geometrie ergibt sich ein Kreis mit einem Radius von 1125 m (siehe Abbildung I.5). Aus Abbildung I.6 kann ein $d\phi$ von $\approx 150^\circ$ über eine Entfernung von $d \approx 2600$ m abgeschätzt werden, was einem Radius von $R \approx 1000$ m entspricht. Daraus lässt sich schließen, dass eine Abweichung von $\approx 10\%$ vom vorgeschlagenen Peilalgorithmus vorliegt. In dieser Arbeit wird nur eine Kurvendetektion ohne weitere Quantifizierung der genauen Krümmung betrachtet. Damit ist die Genauigkeit ausreichend. Schließlich wird ein geeigneter Schwellenwert definiert. Wenn dieser von der Krümmung κ überschritten wird, ist ein signifikanter Einfluss auf die Fahrzeuggeschwindigkeit zu erwarten, und der Krümmungsalgorithmus identifiziert eine Kurve f_{Gv} (vgl. Deufel et al. [3]).

Bestimmung der Fahrbahnsteigung

Für die Berechnung der Fahrbahnsteigung wird auf das Höhensignal, welches sich aus den interpolierten SRTM-Höhendaten ergibt, ebenfalls eine zweistufige Filtermethode angewandt (vgl. Deufel et al. [3]).

- Zum einen umfasst dies einen heuristischen Filter zur Erkennung und Eliminierung von Sprüngen im Signal.
- Anschließend wird analog zu [För20] ein Butterworth-Filter auf das Höhensignal angewendet.

Das Höhensignal aus den interpolierten SRTM-Daten ist in Abbildung I.7 durch eine schwarze gepunktete Linie über der Distanz d dargestellt, durch die Anwendung des Filteralgorithmus ergibt sich die schwarze, durchgezogene Linie. Das Höhenreferenzsignal wird durch eine blaue durchgezogene Linie dargestellt. Die Fahrbahnsteigung wird durch Anwendung des Rechenalgorithmus aus dem Höhensignal bestimmt. Die Fahrbahnsteigung ist dabei über eine rote, durchgezogene Linie eingetragen. Zur besseren Einordnung ist zusätzlich ein Kartenausschnitt dargestellt (vgl. Deufel et al. [3]).




Abbildung I.7: Zweistufige Filtermethode zur Berechnung der Fahrbahnsteigung anhand einer Alpenüberquerung. Der in I.8 dargestellte Ausschnitt ist markiert. Aus Deufel et al. [3].

Grundsätzlich stimmt das Rohsignal der Höhe, das gefilterte Höhensignal und auch das Höhenreferenzsignal gut überein. Bei genauerer Betrachtung des markierten Ausschnitts ergeben sich jedoch deutliche Abweichungen (Abbildung I.8).




Abbildung I.8: Ausgewählte Sequenz zur Validierung der zweistufigen Filtermethode zur Berechnung der Fahrbahnsteigung anhand einer Alpenüberquerung. Aus Deufel et al. [3].

Schwingungen im mikroskopischen Bereich werden grundsätzlich reduziert. Die schwarze durchgezogene Linie (*Höhe gefiltert*) ist gegenüber der schwarz gepunktete Linie des Rohsignals (*Höhe Rohsignal*) deutlich geglättet. Makroskopische Schwankungen, die sich über mehrere Kilometer erstrecken, wie im Fall des Landecker Tunnels in Österreich, können jedoch nicht zuverlässig erkannt und eliminiert werden. In einem solchen Fall geben die SRTM-Daten die tatsächliche Höhe des durchfahrenen Berges wieder, nicht aber die Höhe der eigentlichen Straße. Abgesehen davon gibt es keine Messungen im Tunnel selbst. Daher steigt die schwarz gestrichelte Linie (*Höhe Rohsignal*) bei 275 km auf ca. 940 m bei der Einfahrt in den Tunnel an. Von dort wird sie auf den nächsten gemessenen GNSS-Punkt am Ende des Tunnels (750 m bei 280 km) interpoliert. Im Rahmen der Arbeit wird die zweistufige Filtermethode daher statt auf das gemessene Höhsignal auf das Höhenreferenzsignal (*Höhe Referenzsignal*) angewandt und hieraus schließlich die Fahrbahnsteigung bestimmt (*Fahrbahnsteigung*). Zur Validierung des Algorithmus werden die Höhen- und Fahrbahnsteigungsdaten für die gefahrene Alpenüberquerung mit Literaturdaten verglichen (vgl. Deufel et al. [3]).

J Parametrierung Markov-Ketten und Neuronale Netze

Ergänzend zu Kapitel 6.1 sind im Folgenden Auszüge aus den Parameterstudien sowie die gewählten Einstellparameter dargestellt. Diese Abschnitte sind aus Deufel et al. [1] und [3] entnommen.

Markov-Ketten (MC)

Für die Wahl einer geeigneten Diskretisierung der MC wird eine Initialdiskretisierung, die sich an den Werten der Literatur orientiert [Sil16a, För20], um einen variablen Faktor erhöht. Diese Initialparametrierung ist in Tabelle J.1 aufgezeigt. Angegeben ist die Diskretisierung der Fahrzeuggeschwindigkeit (Δ_v), der Fahrzeugbeschleunigung (Δ_a) und der Fahrbahnsteigung (Δ_α).

Tabelle J.1: Gewählte Diskretisierung für Fahrzeuggeschwindigkeit, Fahrzeugbeschleunigung und Fahrbahnsteigung bei MC.

Δ_v	1 km/h
Δ_a	1 m/s ²
Δ_α	0.5 %

Die Studien sind in Abbildung J.1 dargestellt. Dabei ist jeweils der RMSE für die Fahrzeuggeschwindigkeit, die Fahrzeugbeschleunigung und die Fahrbahnsteigung über der Diskretisierung der Markov-Zustände aufgetragen. Die Werte in Tabelle J.1 stellen einen Diskretisierungsfaktor von 1 dar (vgl. Deufel et al. [1]).




Abbildung J.1: Parameterstudie: RMSE für Fahrzeuggeschwindigkeit, Fahrzeugbeschleunigung und Fahrbahnsteigung in Abhängigkeit von der Diskretisierung der Markov-Zustände. Jeweils mit und ohne Fahrbahnsteigung α . Aus Deufel et al. [1].

Wie man sieht, konvergieren die mittleren quadratischen Abweichungen $RMSE_v$ zu ≈ 5 km/h, $RMSE_a$ konvergiert zu $\approx 0,3$ m/s² für einen Vorhersagehorizont von 10 s für den gewählten Testdatensatz. Für $RMSE_\alpha$ ist keine klare Konvergenz zu identifizieren. Im Hinblick auf die Konvergenz von $RMSE_v$ und $RMSE_a$ kann die Initialparametrierung als geeignet betrachtet werden (vgl. Deufel et al. [1]).

Vorwärtsgerichtetes Neuronales Netzwerk (FFNN)

Das gleiche Verfahren wird für die Auswahl der Anzahl der Neuronen für die versteckten Schichten des FFNN verwendet. Für die Wahl einer geeigneten Anzahl von Neuronen wird die Anzahl der Neuronen in den versteckten Schichten sukzessive reduziert. In Abbildung J.2 sind hierzu jeweils der RMSE für die Fahrzeuggeschwindigkeit, die Fahrzeugbeschleunigung und die Fahrbahnsteigung über der Anzahl der versteckten Schichten $N_{neurons,HL,i}$ aufgetragen. Wie man sieht, konvergiert der $RMSE_v$ zu ≈ 2 km/h und der $RMSE_a$ zu $\approx 0,4$ m/s² für einen Vorhersagehorizont von 10 s für den gewählten Testdatensatz (vgl. Deufel et al. [1]).




Abbildung J.2: Parameterstudie: RMSE für Fahrzeuggeschwindigkeit, Fahrzeugbeschleunigung und Fahrbahnsteigung in Abhängigkeit von der Anzahl der Neuronen in den versteckten Schichten. Jeweils mit und ohne Fahrbahnsteigung α . Aus Deufel et al. [1].

Die gewählten Parameter für das FFNN sind Tabelle J.2 zu entnehmen. Die *Batch Size* gibt dabei an, wie viele Datensätze auf einmal durch das ANN geschleust werden. Eine Epoche beschreibt den Durchlauf aller Trainingsdaten durch das ANN. Die Verlustfunktion bestimmt den Fehler zwischen den vom Modell vorhergesagten Werten und den tatsächlichen Werten. Der Optimierer steuert in Abhängigkeit der gewählten Lernrate die Aktualisierung der Modellparameter um diesen Fehler zu minimieren (vgl. Deufel et al. [1]).

Tabelle J.2: Parameter für FFNN (ohne Steigung und mit Steigung) für 10 Sekunden Vorhersage. Aus Deufel et al. [1].

$N_{neurons,IL}$	10/20
$N_{neurons,OL}$	10/20
N_{HL}	2
$N_{neurons,HL,1}$	20/40
$N_{neurons,HL,2}$	20/40
Optimierer	Adam
Verlustfunktion	Mean Squared Error (MSE)
Aktivierungsfunktion	Rectified Linear Unit (ReLu)
Lernrate	0.001
Batch Size	1400
Epochen	3000

Rekurrentes Neuronales Netzwerk (RNN)

Die Einstellparameter für RNN werden analog gewählt, siehe hierzu Tabelle J.3.

Tabelle J.3: Parameter des RNN aus Deufel et al. [3].

LSTM Einheiten	$N_{horizon}$
Optimierer	Adam
Verlustfunktion	Mean Squared Error (MSE)
Aktivierungsfunktion	Rectified Linear Unit (ReLu)
Lernrate	0.001
Batch Size	1400
Epochen	1000

Für weitere Informationen zu FFNN und RNN sei auf [Gra13, Gra14, Li17, Agg18, Jia18] verwiesen (vgl. Deufel et al. [3]).