

Karlsruher Schriftenreihe
Fahrzeugsystemtechnik

Hans-Georg Wahl

Optimale Regelung eines prädiktiven Energiemanagements von Hybridfahrzeugen



Scientific
Publishing

Hans-Georg Wahl

**Optimale Regelung eines prädiktiven
Energiemanagements von Hybridfahrzeugen**

**Karlsruher Schriftenreihe Fahrzeugsystemtechnik
Band 43**

Herausgeber

FAST Institut für Fahrzeugsystemtechnik

Prof. Dr. rer. nat. Frank Gauterin

Prof. Dr.-Ing. Marcus Geimer

Prof. Dr.-Ing. Peter Gratzfeld

Prof. Dr.-Ing. Frank Henning

Das Institut für Fahrzeugsystemtechnik besteht aus den eigenständigen Lehrstühlen für Bahnsystemtechnik, Fahrzeugtechnik, Leichtbautechnologie und Mobile Arbeitsmaschinen

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

Optimale Regelung eines prädiktiven Energiemanagements von Hybridfahrzeugen

von
Hans-Georg Wahl

Dissertation, Karlsruher Institut für Technologie (KIT)
Fakultät für Maschinenbau, 2015

Impressum



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

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

www.ksp.kit.edu



*This document – excluding the cover, pictures and graphs – is licensed
under the Creative Commons Attribution-Share Alike 3.0 DE License
(CC BY-SA 3.0 DE): <http://creativecommons.org/licenses/by-sa/3.0/de/>*



*The cover page is licensed under the Creative Commons
Attribution-No Derivatives 3.0 DE License (CC BY-ND 3.0 DE):
<http://creativecommons.org/licenses/by-nd/3.0/de/>*

Print on Demand 2015

ISSN 1869-6058

ISBN 978-3-7315-0422-1

DOI: 10.5445/KSP/1000048347

Vorwort des Herausgebers

Die Fahrzeugtechnik ist gegenwärtig großen Veränderungen unterworfen. Klimawandel, die Verknappung einiger für Fahrzeugbau und -betrieb benötigter Rohstoffe, globaler Wettbewerb, gesellschaftlicher Wandel und das rapide Wachstum großer Städte erfordern neue Mobilitätslösungen, die vielfach eine Neudefinition des Fahrzeugs erforderlich machen. Die Forderungen nach Steigerung der Energieeffizienz, Emissionsreduktion, erhöhter Fahr- und Arbeitssicherheit, Benutzerfreundlichkeit und angemessenen Kosten finden ihre Antworten nicht aus der singulären Verbesserung einzelner technischer Elemente, sondern benötigen Systemverständnis und eine domänenübergreifende Optimierung der Lösungen. Hierzu will die Karlsruher Schriftenreihe für Fahrzeugsystemtechnik einen Beitrag leisten. Für die Fahrzeuggattungen Pkw, Nfz, mobile Arbeitsmaschinen und Bahnfahrzeuge werden Forschungsarbeiten vorgestellt, die Fahrzeugsystemtechnik auf vier Ebenen beleuchten: das Fahrzeug als komplexes mechatronisches System, die Fahrer-Fahrzeug-Interaktion, das Fahrzeug in Verkehr und Infrastruktur sowie das Fahrzeug in Gesellschaft und Umwelt.

Die Automatisierung des Autofahrens eröffnet viele Möglichkeiten zur Verbesserung von Fahrzeugeigenschaften. So können etwa der Kraftstoffverbrauch gesenkt und die Verkehrssicherheit und der Komfort erhöht werden. Die detaillierte und stets aktuelle Kenntnis über Parameter des Fahrzeugs, der Strecke, des Verkehrs, der Witterung und des Fahrers erlauben eine Optimierung des Verlaufs der Fahrgeschwindigkeit über der Strecke und der Betriebszustände von Antrieb und weiteren Fahrzeugkomponenten von der aktuellen Fahrzeugposition bis zum Fahrziel. Prädiktive Fahr- und Betriebsstrategien sind leistungsfähig, benötigen jedoch bei einer zunehmenden Anzahl von zu berücksichtigenden Zustandsgrößen und weiterreichendem Prädiktionshorizont performante Rechner und umfangreiche Datenspeicher, die in Fahrzeugen nur in begrenztem Umfang eingesetzt werden können. Der Konflikt wird dadurch verschärft, dass von Systemen der automatisierten Fahrzeugsteuerung Echtzeitfähigkeit zu fordern ist.

Hier setzt die Arbeit von Herrn Wahl an, der aufbauend auf der Optimierungsmethode der deterministischen diskreten dynamischen Programmierung eine mehrstufige, parallelisierbare Regelung und eine Reihe von Konzepten zur Verringerung von Rechenzeit und Speicherplatzbedarf vorschlägt. Er nutzt dabei iterative Ansätze zur Berechnung des globalen Optimums, reduziert die Komplexität des Zustandsraums, vermeidet Diskretisierungsfehler durch die Verwendung kontinuierlicher Zustandswerte, ohne dabei die Anzahl der Zustände zu erhöhen, und nutzt verschiedene Näherungsverfahren zur Beschreibung des Zustandsraums.

Insgesamt erlauben diese Ansätze eine höherdimensionale dynamische Programmierung, bei der Fahr- und Energiemanagementstrategie in einem Rechengang und gegenüber einer sequenziellen Optimierung mit verbessertem Gesamtergebnis berechnet werden können. Überdies schlägt Herr Wahl eine Vorgehensweise vor, bei der Optimierung statistische und aktuelle Verkehrsdaten zu berücksichtigen. Herr Wahl zeigt die Leistungsfähigkeit seiner Ansätze in der Simulation und im realen Fahrzeugversuch über unterschiedlichste Fahrzyklen.

Karlsruhe, im Juni 2015

Frank Gauterin

Optimale Regelung eines prädiktiven Energiemanagements von Hybridfahrzeugen

Zur Erlangung des akademischen Grades
Doktor der Ingenieurwissenschaften
der Fakultät für Maschinenbau
Karlsruher Institut für Technologie (KIT)

genehmigte
Dissertation
von

Dipl.-Ing. Hans-Georg Wahl

Tag der mündlichen Prüfung: 10.06.2015
Hauptreferent: Prof. Dr. rer. nat. Frank Gauterin
Korreferent: Prof. Dr.-Ing. Klaus D. Müller-Glaser

Soli Deo Gloria

Johann Sebastian Bach
(* 1685 - 1750 †)

Danksagung

Die vorliegende Arbeit entstand im Rahmen meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Institut für Fahrzeugsystemtechnik des Karlsruher Instituts für Technologie sowie als Doktorand im Bereich Energiemanagement Gesamtfahrzeug bei der Dr. Ing. h. c. Porsche AG im Kooperationsprojekt ACC InnoDrive. 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 besonders das methodische Arbeiten in meinem Promotionsvorhaben maßgeblich unterstützt und geprägt hat. Seine vielfältigen Anregungen und Diskussionen förderten das Verbinden wissenschaftlichen Denkens mit der praktischen Umsetzung.

Herrn Prof. Dr.-Ing. Klaus D. Müller-Glaser danke ich herzlich für die Übernahme des Korreferats sowie für sein Engagement und treues Begleiten des Kooperationsprojekts schon von den Anfängen an. Ebenso danke ich Herrn Prof. Dr. rer. nat. habil. Ulrich Maas für den Prüfungsvorsitz.

Dr.-Ing. Michael Frey möchte ich für seine wertvollen Anregungen und sein nicht müde werdendes Engagement im Kooperationsprojekt danken.

Innerhalb der Abteilung Energiemanagement Gesamtfahrzeug der Dr. Ing. h. c. Porsche AG danke ich Herrn Dr.-Ing. Matthias Lederer und Dr.-Ing. Frank Weberbauer für die Unterstützung und Förderung meiner Arbeit wie auch für ihr stetiges Interesse an neuen Ansätzen und deren Umsetzung.

Für unzählige Diskussionen, Anregungen und motivierende Gespräche möchte ich mich besonders bei Herrn Marc Holzäpfel bedanken. Viele Ideen und Ansätze entstanden durch ein hervorragendes Miteinander im Team. Meinen Teamkollegen, Kai-Lukas Bauer, Johannes Bach, Stephan Rhode, Henry Patzig, Michal Borsuk und Sebastian Fünfgeld danke ich für die gute Zusammenarbeit, die mir sehr viel Freude bereitet hat.

Wichtiger Bestandteil des Teams waren Studenten, die ich in den zurückliegenden drei Jahren betreuen durfte. Sie haben mit ihrer Arbeit wesentlich zum Gelingen meines Promotionsvorhabens beigetragen. Ich bedanke mich herzlich bei Timo Maul, Dominique Labonte, Kai-Lukas Bauer, Philip Köhler, Matthias Schlegel, Alexander Dyck, Jakob Wiebe, Cornelius Dosch und Michael Klucke.

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. Schließlich möchte ich meiner Familie und im Besonderen meiner wunderbaren Frau danken, die mich unermüdlich unterstützt und motiviert und diese Arbeit mehr mitgeprägt hat als jeder andere.

Kurzfassung

Drei der aktuell wichtigen Trends der Automobilindustrie sind: E-Mobilität, autonomes Fahren und das vernetzte Fahrzeug. Während der elektrifizierte Antriebsstrang Prognosen zu Folge immer größeren Marktanteil bei Neuwagen einnehmen wird, sind die nächsten Schritte von aktuellen Fahrerassistenzsystemen zum autonomen Fahren vorgegeben. Das Einbeziehen von neuen Informationsquellen außerhalb der Fahrzeugsensorik durch unterschiedliche Vernetzungen des Fahrzeugs mit der Außenwelt erschließt unbekannte Möglichkeiten.

Diese Arbeit verbindet diese Trends in einem Entwurf für ein Fahrerassistenzsystem für Hybridfahrzeuge, das die Geschwindigkeitsregelung als auch die Regelung des Energiemanagements optimal übernimmt. Um eine optimale Regelung des Gesamtsystems zu erzielen sind performante Optimierungsalgorithmen notwendig, die zum einen die gleichzeitige Betrachtung von mehrere Zielkriterien wie Komfort, Zeit und Effizienz erlauben und zum anderen möglichst geringe Rechenzeiten bei kleinem Speicherbedarf benötigen. Eine sogenannte Echtzeitoptimierung wird erreicht, indem die Dynamische Programmierung als numerisches Lösungsverfahren durch iterative, heuristische und approximative Berechnungsformen erweitert wird. Da alle verfügbaren Informationen entlang der Strecke bis zum Fahrziel in der Optimierung berücksichtigt werden sollen, wird der Ansatz der Modellbasierten Prädiktiven Regelung durch eine Parallelisierung erweitert. In mehreren Stufen werden so die Informationen unterschiedlicher Prädiktionshorizonte in die Optimierung einbezogen und eine optimale Regelung aller Zielkriterien ist gewährleistet.

In der Simulation wird der entwickelte mehrdimensionale Optimierungsansatz mit der in einem Versuchsfahrzeug installierten heuristischen Strategie zur Steuerung des Energiemanagements verglichen. Dabei kann der Kraftstoffverbrauch durch eine Streckenvorausschau und ohne Längsregelung um 11 % reduziert werden. Wird die Geschwindigkeit in der Optimierung berücksichtigt, kann der Kraftstoffverbrauch bei ähnlich gewählter Durchschnittsgeschwindigkeit um 18 % reduziert werden oder die Durchschnittsgeschwindigkeit bei gleichem Verbrauch um 21 % erhöht werden.

Testfahrten im Versuchsfahrzeug verdeutlichen die Relevanz von genauen Echtzeitverkehrsdaten entlang der gewünschten Route. Aktuelle Verkehrsgeschwindigkeiten aus der Navigation sowie Verkehrsprädiktionsmodelle werden in die Optimierung integriert und analysiert.

Mit aufgezeichneten Verkehrsgeschwindigkeiten auf langen Routen in Mitteleuropa wird die Robustheit der entwickelten Optimierungsalgorithmen zur Regelung des Energiemanagements nachgewiesen und abschließend allgemeine Aussagen zum Potenzial eines Plug-in Hybridfahrzeugs auf Langstrecken getroffen.

Optimal Control of a Predictive Energy Management System for Hybrid Electric Vehicles

Abstract

There are three major trends in automotive industries: E-mobility, autonomous driving and connected car. Forecasts show rising shares in the new car market for electrified powertrains. The next steps from present driver assistance systems to autonomous driving are given. Connecting the vehicle to the outside world unlocks unknown potentials through new information sources.

This work combines these trends in a new design of a driver assistance system for Hybrid Electric Vehicles that overtakes the speed control as well as the control of the energy management. To achieve an overall optimal control, optimization algorithms are necessary that consider multiple criteria such as comfort, time and efficiency on the one hand and need less computing time and memory on the other. A so called real-time optimization is accomplished by extending Dynamic Programming as numerical solving method by iterative, heuristic and approximate calculation variations. All accessible information along the route to the destination are integrated in the optimization. Therefore the principle of Model Predictive Control is chosen and extended by parallelization. The information of different prediction horizons are included in the optimization by several steps so that an optimal control is guaranteed and all criteria are fulfilled.

The developed multi-dimensional optimization approach is benchmarked with a heuristic strategy to control the energy management in a test vehicle. In an investigation without speed control the fuel consumption is reduced by 11 % through road prediction. Including the velocity into the optimization leads to a reduction in the fuel consumption by 18 % and a similar chosen average velocity. In another scenario the average velocity can be increased by 21 % with an equal fuel consumption.

Test drives make clear that precise real time traffic data along the route are necessary. Current traffic speed information and traffic prediction models are integrated into the optimization process and analyzed afterwards.

The robustness of the developed optimization algorithms to control energy management systems is demonstrated by recorded traffic data on long routes through Central Europe. Finally general statements about the potential of a Plug-In Hybrid Electric Vehicle on long routes are made.

Inhaltsverzeichnis

1. Einleitung	1
1.1. Motivation	3
1.2. Gliederung der Arbeit	4
2. Hybrider Antriebsstrang	7
2.1. Antriebsstrangtopologien	7
2.1.1. Hybridisierungsgrad	8
2.1.2. Betrachtete Konzepte	8
2.2. Modellierung eines hybriden Antriebsstrangs	10
2.2.1. Energetische Modellierung einzelner Komponenten	11
2.2.2. Modellierung des Leistungsflusses im Fahrzeug	16
2.2.3. Zustände eines parallelen Hybridantriebsstrangs	21
2.2.4. Dynamische Vorgänge im Antriebsstrang	24
2.3. Validierung des Fahrzeugmodells	27
2.3.1. Ausgewählte Testfälle	29
2.3.2. Fazit	33
3. Betriebsstrategien für Hybridfahrzeuge	35
3.1. Energieeffiziente Fahrstrategien	36
3.1.1. Fahrerassistenzsysteme mit automatisierter Fahrzeughängsführung	37
3.2. Energiemanagementstrategien für Hybridfahrzeuge	38
3.2.1. Heuristische Energiemanagementstrategien	38
3.2.2. Optimale Energiemanagementstrategien	42
3.2.3. Prädiktive Energiemanagementsysteme	46
3.3. Kombination eines prädiktiven Energiemanagements mit einer prädiktiven Fahrstrategie	48
3.4. Fahrzyklen zur Bewertung von Betriebsstrategien	48
3.4.1. Genormte Fahrzyklen	48
3.4.2. Realfahrzyklen	50
3.5. Prädiktive Streckendaten	52
3.5.1. Energetisch optimale Routenplanung	52
3.5.2. Statische Kartendaten	53
3.5.3. Dynamische Karteninhalte	54

3.5.4. Automatische Routenerkennung	57
3.6. Positionierung der Arbeit	58
4. Optimale Modellprädiktive Regelung	61
4.1. Gütemaße einer optimalen Regelung	61
4.1.1. Normierte Kosten	65
4.2. Modellbasierte Prädiktive Regelung (MPC)	67
4.2.1. MPC in der Fahrzeugführung	67
4.2.2. Nichtlineare Modellbasierte Prädiktive Regelung (NMPC)	69
4.3. Echtzeitfähigkeit durch Parallelisierung	70
5. Methoden zur Echtzeitoptimierung mittels	
Dynamischer Programmierung	73
5.1. Mehrstufige Entscheidungsprozesse	73
5.1.1. Optimale Strategie	74
5.1.2. Referenzzyklus	76
5.2. Diskrete Dynamische Programmierung (DDP)	76
5.2.1. Berechnung der Schrittfolgen	77
5.2.2. Diskretisierungseinfluss	78
5.2.3. Fluch der Dimensionen	79
5.2.4. Reduktion des Suchraums	80
5.2.5. Kostenfunktion	83
5.2.6. Vorwärts- und Rückwärtsrechnung	83
5.2.7. Prädiktionshorizont	85
5.3. Iterative Dynamische Programmierung (IDP)	86
5.3.1. Iteration der Strategien	86
5.3.2. Iterative Änderung des Zustandsraums	89
5.3.3. Vergleich: DDP versus IDP	93
5.4. Dynamische Programmierung im kontinuierlichen Zustandsraum	95
5.4.1. Interpolationsproblem: Gewonnene Energie in der Optimierung	95
5.4.2. Boxen-Prinzip	97
5.4.3. Bevorzugte Betrachtung lokal optimaler Zustandsübergänge	98
5.4.4. Mehrdimensionaler Zustandsraum	103
5.4.5. Iterative Berechnung	104
5.5. Approximierte Dynamische Programmierung (ADP)	108
5.5.1. Approximation der Kostenfunktion	109
5.5.2. Approximation der Pfadrückverfolgung	115
5.5.3. Iterative Ausführung der ADP	117
5.5.4. ADP im kontinuierlichen Zustandsraum	120

6. Ein energie- und zeitoptimales Fahrerassistenzsystem für Hybridfahrzeuge	125
6.1. Strategieoptimierung	125
6.1.1. Planung bis zum Ziel: LONGRANGE-Strategie	127
6.1.2. Nahhorizont: MIDRANGE-Strategie	129
6.1.3. Längsregelung: SHORTRANGE-Strategie	135
6.2. Integration in die Fahrzeugarchitektur	138
6.2.1. Sensorik	138
6.2.2. Modul: SYSTEM CONTROL	139
6.2.3. Modul: INPUT	140
6.2.4. Modul: OUTPUT	142
6.2.5. Rapid Prototyping	144
6.3. Simulationsumgebung	144
6.3.1. Systemverhalten	145
7. Implementierung und Test	149
7.1. Simulation der mehrdimensionalen Optimierung	149
7.1.1. Parameterauslegung und Sensitivität	149
7.1.2. Vergleich der optimalen mit der heuristischen Strategie	152
7.1.3. Vergleich serieller und paralleler Optimierung	169
7.2. Fahrversuch und reale Verkehrsdaten	174
7.2.1. Geschwindigkeitsstrategie	174
7.2.2. Leistungsprädiktion	180
7.2.3. Regelungsverhalten	181
7.2.4. Potentialanalyse	185
7.2.5. Langstreckenanalyse	190
8. Zusammenfassung und Ausblick	197

A. Anhang	203
A.1. Eingesetzte Versuchsfahrzeuge	203
A.2. Validierung des Fahrzeugmodells	204
A.3. Fahrzyklen	205
A.4. Metamodellierung der Simulation	208
A.5. Leistungsprädiktion in Längsregelung	210
A.6. Langstreckenanalyse	211
A.6.1. Höhenprofil	211
A.6.2. Reisezeit	214
A.7. Optimale Regelung einer Batteriezustandsplanung	218
B. Abkürzungen, Schreibweisen und Formelzeichen	221
C. Literatur	229
D. Veröffentlichungen und betreute Abschlussarbeiten	245

1. Einleitung

Innovation verbindet Forschung und Industrie, indem Erfindungen umgesetzt werden, die ein im Labor gezeigtes Potenzial durch die Anwendung in einer Vielzahl von Produkten vergrößern. Als eine der wichtigsten Enablers für Innovationen im Auto wird die Elektrik und Elektronik gesehen, wobei durch Kostenoptimierung der Trend von Einzel- hin zu Systeminnovationen geht [38]. Eine Systeminnovation führt Informationen aus einzelnen Komponenten im Fahrzeug zusammen. Dadurch können Systeme realisiert werden, die das Fahrzeug als Ganzes betrachten und es im Sinne der Fahrerassistenz sicherer, komfortabler und effizienter machen. Somit können die großen Trends der nächsten Jahre bedient werden. Drei dieser aktuell wichtigen Trends der Automobilindustrie sind: E-Mobilität, autonomes Fahren und das vernetzte Fahrzeug.

Die **E-Mobilität** und deren Ausbau werden nicht nur vonseiten der Industrie, sondern auch von der Politik vorangetrieben. Die Europäische Union verfolgt das Ziel, die Treibhausgasemissionen im Verkehrssektor bis zum Jahr 2050 um mindestens 60 % des Wertes von 1990 zu senken [47]. Dabei wird der CO₂-Ausstoß bei allen Neuwagen in der EU ab dem Jahr 2015 auf 130 g CO₂/km und ab dem Jahr 2020 auf 95 g CO₂/km begrenzt [137]. In einer Studie des Deutschen Zentrums für Luft- und Raumfahrt wird der Pkw-Markt bis 2040 prädiziert [29]. Dabei wird die Begrenzung des CO₂-Ausstoßes in verschiedenen Szenarien fortgeführt. In einem Szenario wird eine ambitionierte Regulierung angenommen, in der ab 2020 die Begrenzung linear auf 45 g CO₂/km im Jahr 2040 sinkt. Dies hat eine Vielfalt von unterschiedlich elektrifizierten Antriebsstrangkzepten zu Folge. Trotz einer Emissionsvorgabe, haben 85 % der Neufahrzeuge in Deutschland im Jahr 2040 immer noch einen Verbrennungsmotor. Der Anteil der elektrifizierten Neufahrzeuge liegt gleichzeitig bei etwa 80 %. Plug-in Hybride sowie Range-Extender dominieren die elektrifizierten Varianten. Selbst im Gesamtbestand, indem der Neufahrzeugmarkt nur etwa 7 % ausmacht, würde der Anteil der elektrifizierten Antriebe von 3 % in 2020 auf 65 % in 2040 ansteigen. In alternativen Szenarien mit moderaten Regulierungen fällt der Marktanteil an elektrifizierten Antriebssträngen geringer aus, setzt sich aber zunehmend durch und dominiert ebenso in der Prognose für das Jahr 2040. Effizienzsteigernde Technologien werden bei der Studie berücksichtigt und untermauern die zukünftige Nachfrage nach komplexen elektrifizierten Antriebsstrangkzepten. Als weitere Regulierung privilegiert die „Blaue Plakette“ und Hybridfahrzeuge in einer Art erweiterten Umweltzone in Städten

und soll zusammen mit einer City-Maut die Emissionen in den Städten reduzieren [30, 146].

Das **autonome Fahren** ist zum Greifen nahe und wird in vielen Forschungsprojekten der Öffentlichkeit präsentiert: Ein blinder Fahrer wird von Googles modifiziertem Toyota Prius gefahren [125], eine umgebaute Mercedes Benz S-Klasse absolviert die historische Bertha Benz Memorial Route von Mannheim nach Pforzheim vollständig autonom [62] und ein Audi RS7 rast fahrerlos über den Hockenheimring [49]. Die einzelnen Schritte bis zur Serienreife werden dabei weitestgehend einheitlich vorgestellt: Teilautomatisierte Systeme in Form von Autobahn-Piloten mit voll automatisiertem Fahren im Geschwindigkeitsbereich bis 30 km/h stellen die erste Ausbaustufe dar. Dieser baut auf die vorhandene Sensorik eines adaptiven Tempomats auf, wodurch die Längsführung durch die Querverführung aus dem Spurhalteassistenten ergänzt wird. Ab 2020 folgt die Hochautomatisierung, bei der sich der Fahrer in längeren Fahrphasen komplett aus der Fahrzeugführung nehmen kann, um anderen Tätigkeiten nachzugehen. Mit der Einführung der Vollautomatisierung ab 2025 werden der Geschwindigkeitsbereich und die Phasen des autonomen Fahrens ausgeweitet. Es wird weiterhin Situationen geben, in denen der Fahrer die Führung des Fahrzeugs übernehmen muss [34, 37, 119]. Heutige Fahrerassistenzsysteme verwenden schon eine Vielzahl an Sensorik, deren Daten mit immer leistungsfähigeren Prozessoren in Steuergeräten zusammengeführt und verarbeitet werden. Eine Weiterentwicklung dieser Sensoren sowie leistungsfähige Algorithmen ermöglichen das Absichern der jeweiligen Funktion je Ausbaustufe bis hin zum vollständig autonomen Fahren [78].

Das **vernetzte Fahrzeug**¹ umfasst unterschiedliche Funktionen und Schnittstellen im Fahrzeug, die nicht nur den Fahrer, sondern auch das Fahrzeug mit dem Internet und so mit einer Vielzahl von Diensten vernetzt. Der Zustand des Fahrzeugs kann z. B. in Echtzeit überwacht werden und so die Zeit in den Werkstätten reduziert werden. Unterhaltungs- und Informationsdienste, die vor allem der „Generation Internet“ sehr vertraut sind, nehmen Einzug in das Fahrerlebnis [118]. In einem Notfall werden Einsatzkräfte direkt informiert², während andere Verkehrsteilnehmer über Car-to-Car (C2C) oder Car-to-Infrastructure (C2I)³ gewarnt werden sollen [142]. Durch die Schnittstelle nach außen sind neue Sicherheitsstandards in der Systemarchitektur erforderlich [46]. Gerade im Blick auf automatisierte Fahrfunktionen müssen elektronische Systeme im Fahrzeug gemäß Normen⁴ abgesichert werden.

Die Vernetzung des Fahrzeugs zur Umwelt bietet sowohl für die E-Mobilität als auch bei automatisierten Fahrsystemen Potenzial. Präzise Informationen, die im Fahrzeug durch Sensoren gesammelt werden, können zur Verfügung gestellt werden.

¹ engl. Connected Car

² Der sogenannte eCall soll in jedem Neuwagen ab Oktober 2015 verfügbar sein [95]

³ Eine allgemeine Bezeichnung, die beides umfasst, ist Car2X

⁴ Die ISO 26262 Norm wird für sicherheitsrelevante Systeme in Kraftfahrzeugen verwendet

Einzelne Informationsquellen bilden einen Verkehr ab, der weit über den Sensorhorizont hinaus abgefragt werden kann. Verkehrsmodelle aus der Navigation können genutzt werden, um Geschwindigkeiten auf Straßenabschnitten für automatisiertes Fahren sowie die elektrische Reichweite eines Fahrzeugs anhand der Verkehrssituation besser abzuschätzen. Das Sammeln und Verarbeiten dieser großen Mengen an Daten muss nicht im Fahrzeug stattfinden und kann zentral auf Servern⁵ erfolgen. Diese stellen nur solche Informationen über Schnittstellen zu Verfügung, die je nach Anfrage relevant sind. Aus Sicht des Fahrzeugs kann das Internet auch als eine Art Sensor verstanden werden, der die Sensorik im Fahrzeug mit Informationen zukünftig ergänzt.

1.1. Motivation

Verbindet man die drei genannten Trends in einem Fahrzeug von morgen, kann dieses wie folgt charakterisiert sein:

- Der Antriebsstrang ist elektrifiziert.
- Sicherheit, Komfort und Effizienz bestimmen das Fahrverhalten.
- Effiziente Energiemanagementsysteme werden mit der Navigation gekoppelt und ermöglichen im Fahrzeug Kraftstoffeinsparungen im Realbetrieb.
- Das Umfeld eines Fahrzeugs wird über eine große Anzahl an Sensoren aufgenommen und interpretiert.
- Das Fahrzeug wird vernetzt sein und unter anderem Informationen für die Fahrt empfangen.
- Die Fahrzeugführung wird über ein Fahrerassistenzsystem im ersten Schritt teilweise und später vollständig übernommen.

Die Umsetzung dieser Merkmale lässt sich durch ein Fahrerassistenzsystem realisieren, das sowohl einen elektrifizierten Antriebsstrang als auch die Fahrstrategie in Form einer Längsregelung optimal steuert. Dabei wird die elektrische Energie im Fahrzeug entsprechend der Route optimal eingesetzt, ohne dass der Fahrer durch die Wahl von Betriebsmodi eingreifen muss. Eine effiziente Fahrweise im Sinne einer Geschwindigkeitsregelung und automatischen Gangwahl muss aber nicht unbedingt in einer niedrigen Durchschnittsgeschwindigkeit resultieren. Während Sicherheit und Komfort gewährleistet sind, kann die Ausprägung des Systems sowohl zeitoptimal als auch energieoptimal parametrierbar werden.

Ein derartiges zeit- und energieoptimales Fahrerassistenzsystem muss über eine zentrale Instanz verfügen, die sowohl eine langfristige Planung bis zum Fahrtziel

⁵ In der Informationstechnik können Server auch als Back-End bezeichnet werden

beinhaltet, als auch die kurzfristige Steuerung und Regelung des Antriebsstrangs übernimmt. Informationen werden über die Sensorik im Fahrzeug gesammelt, aber auch über eine Schnittstelle zu einem Back-End (Car2X) empfangen und müssen schnell verarbeitet werden. Die Komplexität eines hybriden Antriebsstrangs sowie die Menge an relevanten Daten entlang der Strecke erfordern leistungsfähige Optimierungsalgorithmen, die auch in Zukunft alle zusätzlich verfügbaren Informationen verarbeiten können.

Verwandte wissenschaftliche Arbeiten, die in Kapitel 3 ausführlich vorgestellt werden, betrachten die Zielanforderungen getrennt und widmen sich größtenteils der Lösung eindimensionaler Optimierungsprobleme, wodurch das Potenzial, das durch Wechselwirkungen der Längsregelung und des Energiemanagements entsteht, nicht vollständig ausgenutzt werden kann. Eine optimale Umsetzung des skizzierten Fahrerassistenzsystems im Fahrzeug ist daher nur durch geeignete Optimierungsalgorithmen realisierbar, die zum einen mehrdimensionale Aufgabenstellungen lösen und zum anderen diese auch in Echtzeit berechnen können. Diese Optimierungsmethoden sowie deren Zusammenspiel sind Kern dieser Arbeit und ermöglichen durch Reduktion der Rechenzeit und des Speichers eine echtzeitfähige Umsetzung des Systems im Fahrzeug.

1.2. Gliederung der Arbeit

Die vorliegende Arbeit ist wie folgt gegliedert:

In **Kapitel 2** werden Antriebsstrangkonzepete von Hybridfahrzeugen vorgestellt. Ein paralleles Hybridfahrzeug wird beispielhaft modelliert. Dieses Fahrzeugmodell wird in den Optimierungsalgorithmen sowie für die Simulationen verwendet. Eine Validierung des Fahrzeugmodells erfolgt anhand von einzelnen Funktionen und gemessenen Fahrzeugsignalen.

Kapitel 3 beschreibt verschiedene Betriebsstrategien für Hybridfahrzeuge. Dabei werden aus dem Bereich der Fahrerassistenzsysteme Fahrstrategien und Strategien für das Energiemanagement des hybriden Antriebsstrangs unterschieden sowie verwandte Arbeiten und Methoden vorgestellt. Untersuchungen erfolgen auf Basis von Fahrzyklen, die entweder durch ein Geschwindigkeits- und Höhenprofil vorgegeben sind oder über prädiktive Streckendaten und Echtzeitverkehrsinformationen in der Simulation und im Fahrzeug erzeugt werden. Abschließend wird die Arbeit in themenverwandte, wissenschaftliche Arbeiten eingegliedert sowie der wissenschaftliche Beitrag hervorgehoben.

Grundlagen einer optimalen Regelung werden in **Kapitel 4** vorgestellt. Gütemaße einer multikriteriellen Optimierung, die bei Untersuchungen in Kapitel 7 die Ergebnisse bestimmen, werden definiert. Das Konzept der „Modellbasierten Prädiktiven Regelung“ wird anhand einer Fahrzeugführung vorgestellt und durch eine Parallelisierung

erweitert, sodass eine echtzeitfähige Regelung auch bei komplexen Modellen und Optimierungsalgorithmen möglich ist.

Die „Dynamische Programmierung“ wird als numerisches Optimierungsverfahren gewählt. Unter dem Fokus der Echtzeioptimierung werden verschiedene Methoden, die auf der Dynamischen Programmierung basieren, in **Kapitel 5** vorgestellt. Verfahren aus anderen Disziplinen werden auf die Optimierungsprobleme der Fahr- und Energiemanagementstrategien angepasst und neue Techniken entwickelt, um eine mehrdimensionale Optimierung zu ermöglichen. Die Vor- und Nachteile in Bezug auf Genauigkeit, Rechenzeit und Speicheranforderung werden für jede Methode diskutiert.

Basierend auf dem Prinzip einer mehrstufigen Modellbasierten Prädiktiven Regelung und verschiedenen Methoden zur Echtzeioptimierung wird in **Kapitel 6** der Aufbau eines energie- und zeitoptimalen Fahrerassistenzsystems für Hybridfahrzeuge vorgestellt. Dabei wird jedes Teilsystem und dessen Integration in die Fahrzeugarchitektur detailliert beschrieben.

Die Analyse der entwickelten Optimierungsalgorithmen in Simulation und Fahrversuch ist Inhalt von **Kapitel 7**. Der erste Teil widmet sich einem Vergleich der im Versuchsfahrzeug vorhandenen Basisstrategie mit prädiktiven Strategien. Dabei werden sowohl die Potenziale zur Reduktion des Kraftstoffverbrauchs durch die Prädiktion, als auch durch die kombinierte Optimierung mit der Fahrstrategie betrachtet.

In einem zweiten Teil werden die Potenziale eines vorausschauenden Energiemanagements in einzelnen Messfahrten sowie auf Basis von Verkehrsdaten und Verkehrsprädiktionsmodellen bestimmt. In Messfahrten und Aufzeichnungen von Geschwindigkeitsinformationen über Datenlieferanten auf verschiedenen Fahrzyklen und Langstrecken kann die Robustheit der Optimierungsverfahren nachgewiesen werden sowie allgemeine Aussagen über Potenziale eines Plug-in Hybridfahrzeugs auch bei langen Fahrtstrecken von mehrere hundert Kilometern getroffen werden.

Kapitel 8 schließt mit einer Zusammenfassung und gibt einen Ausblick auf mögliche Weiterentwicklungen und Anwendungen der erarbeiteten Methoden.

2. Hybrider Antriebsstrang

In der europäischen Norm für die Genehmigung der Fahrzeuge hinsichtlich der Schadstoffemission [1] wird ein *Hybridfahrzeug als ein Fahrzeug mit mindestens zwei verschiedenen (fahrzeugeigenen) Energiewandlern und -speichern für den Antrieb des Fahrzeugs* definiert. Genauer spezifiziert ist das *Hybrid-Elektrofahrzeug⁶ (HEV), das aus beiden fahrzeugeigenen Energiequellen Kraftstoff und ein elektrisches Energiespeicher-System (z. B. Batterie, Kondensator, Schwungrad usw.) mit Energie für den mechanischen Antrieb versorgt wird.*

2.1. Antriebsstrangtopologien

Der Aufbau des Antriebsstrangs eines HEV und die Kombination unterschiedlicher Komponenten erlauben nach [80] die Klassifikation in drei Grundstrukturen:

- **Serieller Hybridantrieb:** Die E-Maschine treibt allein das Fahrzeug an. Die benötigte elektrische Energie kommt aus der Batterie, die wiederum durch einen Verbrennungsmotor⁷ (ICE) und einem Generator geladen werden kann. (Kein mechanischer Durchtrieb des ICE zum Rad)
- **Paralleler Hybridantrieb:** Sowohl der Verbrennungsmotor als auch die E-Maschine können über eine mechanische Verbindung am Antriebsstrang antreiben. (Mechanischer Durchtrieb des ICE zum Rad)
- **Leistungsverzweigter und kombinierter Hybridantrieb:** Ein leistungsverzweigtes Getriebe ermöglicht ein stufenloses Verteilen der mechanischen Leistung des ICE auf den Fahrzeugvortrieb als auch auf die elektrischen Energiewandler.

Weiter kann unterschieden werden, auf wie viele Antriebswellen die Aggregate einwirken. Bei einer Einwellenanordnung wirken sowohl E-Maschine als auch Verbrennungsmotor auf dieselbe Welle. Bei der Zweiwellenanordnung wirken die Aggregate auf verschiedene Wellen. Ein Getriebe vereint die Wirkungen auf eine Antriebswelle.

Je nach Auslegung der Aggregate dominiert die installierte elektrische Leistung gegenüber der verbrennungsmotorischen Leistung. Zum Vergleich unterschiedlicher Fahrzeugkonzepte dient der Hybridisierungsgrad.

⁶ engl. Hybrid Electric Vehicle

⁷ engl. Internal Combustion Engine

2.1.1. Hybridisierungsgrad

Der Hybridisierungsgrad⁸ H ist nach [61] als der Quotient aus der Summe der Leistungen aller installierten E-Maschinen zur installierten Gesamtleistung definiert:

$$H = \frac{\sum P_{EM,max}}{\sum P_{EM,max} + P_{ICE,max}} \quad (2.1)$$

Bei $H = 0 \%$ wird das Fahrzeug rein verbrennungsmotorisch angetrieben, während $H = 100 \%$ einen rein elektrischen Antrieb darstellt.

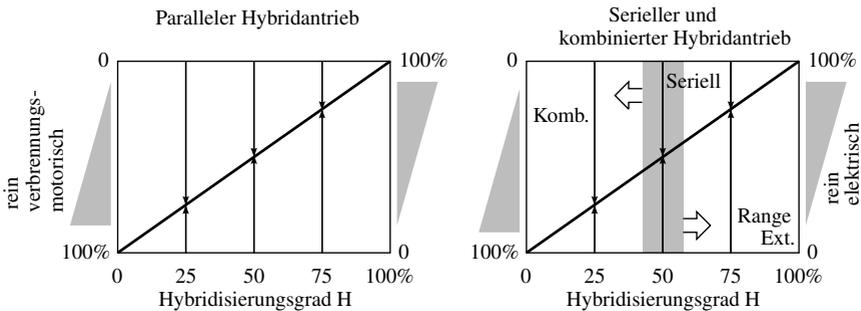


Abb. 2.1.: Hybridisierungsgrad H für unterschiedliche Hybridkonzepte nach [61]

Während die parallele Antriebsform in den unterschiedlichsten Hybridisierungsgraden verwendet wird, ist der Hybridisierungsgrad eines seriellen Hybrids im Bereich um $H = 50 \%$ festgelegt [61]. Wie in Abb. 2.1 dargestellt wird ein serieller Hybrid mit mehr als 50% Hybridisierung als *Range-Extender* bezeichnet. Kombinierte Hybride haben in der Regel einen Hybridisierungsgrad $H < 50 \%$. Hybridelektrische Fahrzeuge können je nach Funktionsumfang weiter unterteilt werden (siehe Tab. 2.1). Mit zunehmendem Hybridisierungsgrad nimmt die elektrische Reichweite⁹ (AER) zu.

2.1.2. Betrachtete Konzepte

Der Antriebsstrang eines parallelen HEVs kann weiter unterschieden werden. In Abb. 2.2 sind mögliche Positionen einer E-Maschine in einem parallelen Antriebsstrang nach [70] eingezeichnet. Bei einem Riemen- oder Kurbelwellen- Startergenerator (P0,P1) ist die E-Maschine direkt an den Verbrennungsmotor gekoppelt. Bei einem P2 Konzept ist die E-Maschine auf der Getriebeeingangswelle positioniert.

⁸ engl. Hybridness

⁹ engl. All Electric Range

Tab. 2.1.: Funktionsumfang unterschiedlicher Hybridkonzepte nach [41]

	Micro-Hybrid MCHEV	Mild-Hybrid MHEV	Full-Hybrid FHEV	Plug-In Hybrid PHEV	Battery Elec. Vehicle BEV
Rekuperation	Ja	Ja	Ja	Ja	Ja
Start/Stop	Ja	Ja	Ja	Ja	Ja
E-Maschine	< 2 kW	10-15 kW	15-60+ kW	30-120+ kW	30-120+ kW
Batterie	< 1 kWh	0,5-1,5 kWh	1,5-2,5 kWh	5-15 kWh	15-35 kWh
Spannung	12 V	120-130 V	200-270 V	300-400 V	300-600 V
Boost	Nein	< 15 kW	> 15 kW	> 30 kW	Nein
E-Fahren	Nein	Nein	1-3 km	20-60 km	80-160+ km
H=	≈ 0,03	≈ 0,1	> 0,25	> 0,5	1

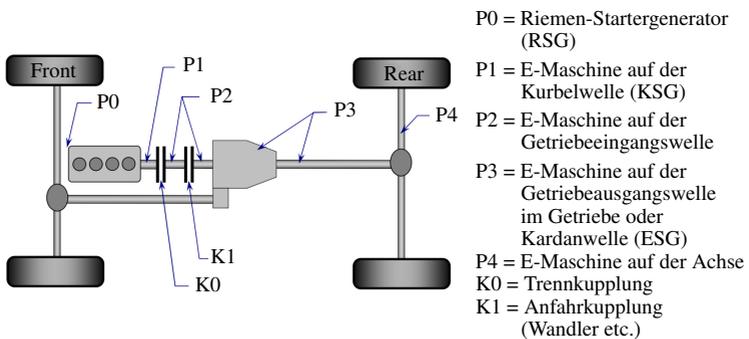


Abb. 2.2.: Mögliche Anordnungen der E-Maschine in einem parallelen HEV [70]

Trenn- und Anfahrkupplungen (K0,K1) erlauben ein Abkoppeln des Verbrennungsmotors. Bei P3 Konzepten ist die E-Maschine an der Getriebeausgangsseite oder auch im Getriebe zu finden, während die E-Maschine beim P4 Konzept auf der Achse antreibt.

Die in dieser Arbeit betrachteten Konzepte entsprechen einem parallelen Antriebsstrang mit einer P2 Anordnung der E-Maschine, die zwischen einem Wandler (K1) und der Getriebeeingangsseite angebracht ist. Der Funktionsumfang bei den Versuchsfahrzeugen entspricht einem Full-Hybrid und einem Plug-in Hybrid, die sich prinzipiell in der Leistung der E-Maschine und der Batteriegröße unterscheiden. Aufgrund eines leistungsstarken Verbrennungsmotors ergeben sich die Hybridisierungsgrade zu $H_{\text{FHEV}} = 13,9 \%$ und $H_{\text{PHEV}} = 28,6 \%$. Die Versuchsfahrzeuge sind in Anhang A.1 genauer beschrieben.

2.2. Modellierung eines hybriden Antriebsstrangs

Bei der Modellierung des Antriebsstrangs wird im Allgemeinen zwischen zwei Ansätzen unterschieden, der dynamischen und der quasi-statischen Modellbildung. Der dynamische Ansatz geht nach dem physikalischen Prinzip von Ursache und Wirkung vor, weswegen er auch als *kausal* bezeichnet wird. Dabei werden alle relevanten Komponenten des Antriebsstrangs in der Regel durch Differentialgleichungen in Zustandsraumdarstellung beschrieben [68].

Wie in Abb. 2.3 dargestellt, dient eine Geschwindigkeitsstrategie (V-Strategie), die meist einen Fahrzyklus repräsentiert, einem Regler als Sollvorgabe. Den Geschwindigkeitsregler kann der Fahrer oder ein Längsregelsystem darstellen. Das Energiemanagement (SoC¹⁰-Strategie) steuert die beiden Aggregate. Das Gesamtmoment von Verbrennungsmotor (ICE) und Elektromotor (EM) liegt bei einer geschlossenen Kupplung am Getriebeeingang an. Über Differential und Rad wird das Moment auf die Straße umgesetzt. Die Fahrwiderstände beeinflussen die Geschwindigkeit, mit der sich das Fahrzeug fortbewegt, was wiederum dem Regler zurückgeführt wird. Das zeitliche Verhalten der Komponenten lässt sich durch den kausalen Ansatz sehr gut abbilden. Das mehrfache Lösen von Differentialgleichungen stellt aber, verglichen mit dem quasi-statischen Ansatz, einen hohen Rechenaufwand dar.

Der quasi-statische oder nicht-kausale Ansatz wirkt entgegen dem physikalischen Grundprinzip und wird deshalb auch oft als Rückwärtssimulation bezeichnet. Ausgehend von einer Geschwindigkeitsvorgabe wird über die Fahrwiderstände ein Radmoment berechnet. Das Getriebeeingangsmoment fließt als gefordertes Gesamtmoment in die Energiemanagementstrategie, die die Momentenaufteilung der Aggregate bestimmt. Das Ergebnis ist der Verbrauch \dot{m}_f und die elektrische Leistung P_{el} für den betrachteten quasistationären Zustand. Die nicht-kausale Modellierung eignet sich besonders bei der Optimierung des Verbrauchs in komplexen Antriebssträngen durch einen niedrigeren Rechenaufwand.

¹⁰ engl. State of Charge

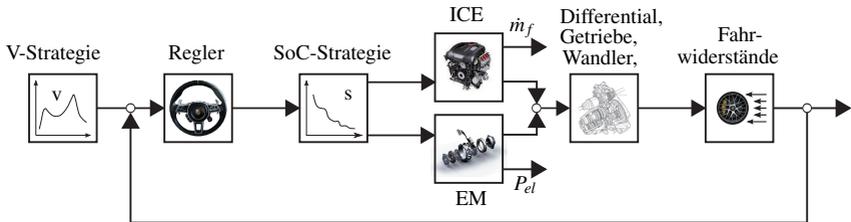
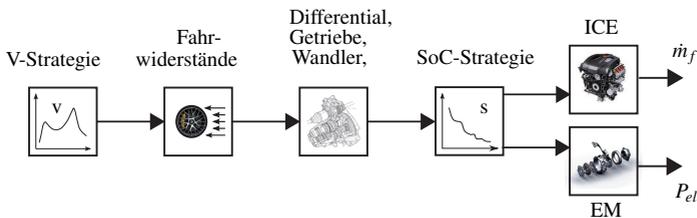
Kausale Modellierung:Nichtkausale Modellierung:

Abb. 2.3.: Vergleich einer kausalen und nichtkausalen Modellierung

Dynamische Vorgänge können nur berücksichtigt werden, wenn sie vorher bekannt und invertierbar sind [68]. Da das Zeitverhalten einer Batterie einen Einfluss auf das optimale Energiemanagement darstellt, kombiniert BACK [12] die beiden Ansätze indem er nur die Batterie dynamisch und die restlichen Komponenten im Antriebsstrang quasi-statisch modelliert.

In der vorliegenden Arbeit fließen sowohl die Geschwindigkeitsstrategie als auch die Batterieladestrategie in die Optimierung ein. Es wird der nicht-kausale Ansatz zur Modellierung gewählt, da durch eine große Anzahl von Iterationen ein Ansatz mit möglichst geringem rechnerischem Aufwand notwendig ist. Relevante dynamische Vorgänge werden separat untersucht und aus energetischer Sicht in quasistationärer Form in das Modell eingefügt (siehe Abschnitt 2.2.4).

2.2.1. Energetische Modellierung einzelner Komponenten

Im Folgenden werden einzelne Komponenten des Fahrzeugmodells betrachtet. Dabei liegt der Fokus auf der Fahrzeuglängsdynamik und deren Einfluss auf die Berechnung des Energiebedarfs.

Fahrwiderstände

Ein Fahrzeug muss zur Fortbewegung eine Summe von Fahrwiderständen überwinden, die in einem Gesamtfahrwiderstand F_x zusammengefasst werden. Die einzelnen Fahrwiderstände lassen sich in stationäre und instationäre Fälle unterscheiden [75]. Bei einer konstanten Geschwindigkeit (stationär) treten Luftwiderstände (F_L), Radwiderstände (F_R), und Steigungswiderstände (F_{St}) auf, während bei einer beschleunigten Fahrt (instationär) die Beschleunigungswiderstände F_a dazukommen. Der zu überwindende Gesamtwiderstand ist wie folgt definiert¹¹:

$$F_x = F_L + 4 \cdot F_R + F_{St} + F_a \quad (2.2)$$

Luftwiderstand: Der Luftwiderstand F_L besteht aus mehreren Anteilen. Die entscheidenden Widerstandsformen sind nach [75] Druckwiderstand und Reibungswiderstand. Hinzu kommt der innere Luftwiderstand, da das Fahrzeug keinen geschlossenen Körper darstellt, sondern teilweise durchströmt wird. Der induzierte Luftwiderstand bildet z. B. Verwirbelungen ab.

Der Druckwiderstand wird aus dem Staudruck $p_\infty = \frac{\rho_L}{2} \cdot v_\infty^2$, bestehend aus Luftdichte ρ_L und Anströmgeschwindigkeit v_∞ , der senkrecht zur Strömungsrichtung projizierten Fahrzeugfläche A_L und dem dimensionslosen Luftwiderstandsbeiwert¹² $c_x(\phi)$ berechnet. Der Luftwiderstandsbeiwert ist abhängig von einem Anströmwinkel ϕ :

$$F_L = p_\infty \cdot c_x(\phi) \cdot A_L = \frac{\rho_L}{2} \cdot v_\infty^2 \cdot c_x(\phi) \cdot A_L \quad (2.3)$$

Die Anströmgeschwindigkeit ist die Vektorsumme aus Fahrzeuggeschwindigkeit v_x und Strömungsgeschwindigkeit v_L :

$$\vec{v}_\infty = \vec{v}_x + \vec{v}_L \quad (2.4)$$

Radwiderstände: Der Gesamtradwiderstand F_R setzt sich aus mehreren Anteilen zusammen [75]. Davon werden in dieser Arbeit folgende Anteile betrachtet¹³:

- Anteil des Reifens (Rollwiderstand) $F_{R,R}$
- Anteil durch Schräglauf (Kurvenwiderstand und Vorspurwiderstand) $F_{R,K}, F_{R,V}$
- Anteil durch Lagerreibung $F_{R,L}$

¹¹ Es wird die Annahme getroffen, dass die Radlast und der Fülldruck an allen vier Rädern gleich sind und eine einheitliche Bereifung an Vorder- und Hinterachse vorliegt.

¹² Es wird die Annahme getroffen, dass der Anströmwinkel $\phi = 0^\circ$ beträgt und damit $c_x = c_w$ gilt.

¹³ Der Schlupfwiderstand wird vernachlässigt, da hochdynamische Fahrzustände in der Aufgabenstellung nicht vorgesehen sind.

Der **Rollwiderstand** setzt sich wiederum aus einzelnen Anteilen zusammen. Vernachlässigt man Temperatur und Fahrbahnbeschaffenheit, ergibt sich mit Rollwiderstandsbeiwert f_R und Fahrbahneigungswinkel α der Rollwiderstand zu:

$$F_{R,R} = \frac{1}{4} \cdot m \cdot g \cdot f_R \cdot \cos(\alpha) \quad (2.5)$$

Der Rollwiderstandsbeiwert f_R weist eine geringe Abhängigkeit von der Radlast, aber eine hohe Abhängigkeit von der Längsgeschwindigkeit v_x auf. Da $f_R \sim v_x^2$, kann f_R durch ein Polynom zweiten Grades angenähert werden. Basierend auf den Längen (l, l_h, l_v) aus dem Einspurmodell erfolgt eine getrennte Betrachtung der Vorder- und Hinterachse [75][180]:

$$f_R \approx \frac{1}{l} \cdot (l_h(c_{0,v} + c_{1,v} \cdot v_x + c_{2,v} \cdot v_x^2) + l_v(c_{0,h} + c_{1,h} \cdot v_x + c_{2,h} \cdot v_x^2)) \quad (2.6)$$

Bei der Kurvenfahrt wirkt die Zentrifugalkraft $F_Z = m \cdot \kappa \cdot v_x^2$ mit der Kurvenkrümmung κ auf den Fahrzeugschwerpunkt. Durch den Schräglaufwinkel β_v und β_h entstehen Seitenkräfte $F_{y,v}$ und $F_{y,h}$, die den Radwiderstand erhöhen. Bei einer stationären Kurvenfahrt wirkt der **Kurvenwiderstand** $F_{R,K}$ in Längsrichtung, der nach folgender Gleichung unter der Anwendung des Einspurmodells berechnet wird [121]:

$$F_{R,K} = m \cdot \kappa \cdot v_x^2 \cdot \left(\frac{l_h}{l} \cdot \sin(\beta_v) + \frac{l_v}{l} \cdot \sin(\beta_h) \right) \quad (2.7)$$

Die linearen Seitenkräfte $F_{y,v}$ und $F_{y,h}$ können über die Schräglaufsteifigkeiten $C_{lat,v}$, $C_{lat,h}$ der Vorder- und Hinterachsen definiert werden [121][71]:

$$F_{y,v} = C_{lat,v} \cdot \beta_v = m \cdot \kappa \cdot v_x^2 \cdot \frac{l_h}{l} \quad (2.8)$$

$$F_{y,h} = C_{lat,h} \cdot \beta_h = m \cdot \kappa \cdot v_x^2 \cdot \frac{l_v}{l} \quad (2.9)$$

Unter der Annahme, dass sich der Schräglaufwinkel linear mit der Seitenkraft verändert¹⁴, können die Schräglaufwinkel in Gl. (2.7) durch Gl. (2.8) und (2.9) ersetzt werden:

$$\bar{F}_{R,K} = \left(\frac{m \cdot \kappa \cdot v_x^2}{l} \right)^2 \cdot \left(\frac{l_h^2}{C_{lat,v}} + \frac{l_v^2}{C_{lat,h}} \right) \quad (2.10)$$

Der Vorspurwinkel ψ entspricht einem Schräglaufwinkel bei Geradeausfahrt durch Verspannung von Lenkgestänge und Radaufhängung.

¹⁴ $\sin \beta \approx \beta$ für kleine Winkel

Wie beim Kurvenwiderstand berechnet sich der **Vorspurwiderstand** gemäß dem Einspurmodell für kleine Winkel ψ zu:

$$F_{R,V} = C_{\text{lat},v} \cdot \psi_v^2 + C_{\text{lat},h} \cdot \psi_h^2 \quad (2.11)$$

Bei der Lagerreibung ist diejenige Kraft von Interesse, die Auswirkung auf die Fahrbahnebene hat. Sie wird mithilfe des dynamischen Radhalbmessers r_{dyn} und dem Lagerhalbmesser r_L sowie dem Lagerbeiwert μ_L bestimmt:

$$F_{R,L} = m \cdot g \cdot \mu_L \cdot \frac{r_L}{r_{\text{dyn}}} \quad (2.12)$$

Der Gesamtradwiderstand F_R ist die Summe aller betrachteten Teilwiderstände:

$$F_R = F_{R,R} + F_{R,K} + F_{R,V} + F_{R,L} \quad (2.13)$$

Steigungswiderstand: Bei einer Fahrbahnsteigung mit dem Steigungswinkel α wirkt auf den Fahrzeugschwerpunkt eine Hangabtriebskraft als Sinusanteil der Gesamtgewichtskraft F_N in Fahrzeuglängsrichtung:

$$F_{St} = F_N \cdot \sin(\alpha) = m \cdot g \cdot \sin(\alpha) \quad (2.14)$$

Nach [75] ist die Straßensteigung p definiert als Quotient aus vertikaler und horizontaler Fahrbahnprojektion, was dem Tangens des Steigungswinkels entspricht:

$$p = \tan(\alpha) \quad (2.15)$$

Eingesetzt in Gl. (2.14) folgt:

$$F_{St} = m \cdot g \cdot \sin(\arctan(p)) = m \cdot g \cdot \frac{p}{\sqrt{1+p^2}} \quad (2.16)$$

Beschleunigungswiderstand: Nach [75, 121] setzt sich der Beschleunigungswiderstand F_a aus einer translatorischen Kraft $F_{a,\text{trans}}$ und einer rotatorischen Kraft $F_{a,\text{rot}}$ zusammen:

$$F_a = F_{a,\text{trans}} + F_{a,\text{rot}} \quad (2.17)$$

Die rotatorische Kraft lässt sich über dem am Rad angreifenden Moment T_R und dem Radhalbmesser r_{dyn} beschreiben, während das Moment mit dem Drallsatz bestimmt wird:

$$F_{a,\text{rot}} = \frac{T_R}{r_{\text{dyn}}} = \frac{\Theta_{\text{red}} \cdot \dot{\omega}_l}{r_{\text{dyn}}} \quad (2.18)$$

Da im Antriebsstrang unterschiedliche Drehzahlen je Gang und Übersetzungsstufe möglich sind, variiert das reduzierte Massenträgheitsmoment des gesamten Antriebsstrangs $\Theta_{\text{red}}(z, c)$ ¹⁵ je Gang und binärem Zustand der Trennkupplung c [180]:

$$\begin{aligned} \Theta_{\text{red}}(z, c) = & ((J_{\text{ICE}} + J_{\text{flywheel}} + J_{\text{clutch,in}}) \cdot c + \\ & (J_{\text{clutch,out}} + J_{\text{EM}}) \cdot (i_D \cdot i_G(z))^2 + \\ & (J_{\text{GB}}(z) + J_{\text{c,shaft}} + J_{\text{diff,in}}) \cdot i_D^2 + \\ & (2 \cdot J_{\text{diff,out}} + 4 \cdot J_{\text{brake}} + 4 \cdot J_{\text{bearing}} + 4 \cdot J_{\text{wheel}}) \end{aligned} \quad (2.19)$$

Der Beschleunigungswiderstand kann durch einen Drehmassenzuschlagsfaktor $e(z, c)$ und bei Vernachlässigung des Schlupfs vereinfacht beschrieben werden.

$$F_a = \left(m + \frac{\Theta_{\text{red}}(z, c)}{r_{\text{dyn}}^2} \right) \cdot a_x = m \cdot e(z, c) \cdot a_x \quad (2.20)$$

Ausrollkurven: Die Hauptbestandteile der Fahrwiderstände sind bei konstanter Fahrt in der Ebene Roll- und Luftwiderstände. Mit der Annahme, dass sich die Rollwiderstände linear mit der Geschwindigkeit ändern und der Luftwiderstand ausschließlich Geschwindigkeitsanteile 2. Ordnung enthält, kann man den Geschwindigkeitsverlauf einer Ausrollmessung als Polynom 2. Ordnung darstellen [117]. Unter idealisierten Bedingungen werden der Rollwiderstandsbeiwert f_R und der Luftwiderstandsbeiwert c_w durch mehrere Messungen bestimmt. Mit diesen Messungen kann mittels Regression der Fahrwiderstand für diesen Spezialfall durch ein Polynom 2. Ordnung angenähert werden:

$$F_{x,\text{abc}}(v_x) = a + b \cdot v_x + c \cdot v_x^2 \quad (2.21)$$

Leistungs- und Energiebedarf: Der erforderliche Leistungsbedarf P_{ges} errechnet sich aus dem Gesamtwiderstand F_x und der gefahrenen Geschwindigkeit v_x :

$$P_{\text{ges}} = F_x(v_x) \cdot v_x \quad (2.22)$$

Die aufzuwendende Gesamtenergie lässt sich sowohl als Integral der Leistung über der Zeit t_x als auch als Integral der Fahrwiderstände über der zurückgelegten Strecke s_x bestimmen:

$$E_{\text{ges}} = \int_0^{t_x} P_{\text{ges}} \cdot dt = \int_0^{s_x} F_x \cdot ds \quad (2.23)$$

Wird der Schlupf vernachlässigt, so stimmt der Leistungsbedarf P_{ges} der Radleistung $P_R \approx P_{\text{ges}}$ näherungsweise überein [121].

¹⁵ Je nachdem ob die Trägheit des Schwungrads beim Messsignal des Motordrehmoments schon berücksichtigt wird, fällt J_{ICE} in Gl. (2.20) weg.

Fahrwiderstandsadaption: Die Güte der Fahrwiderstände ist direkt proportional zur Güte des prädierten Leistungs- und Energiebedarfs. Entscheidende Modellfehler entstehen durch die Verwendung von Fahrwiderstandsparametern, die unter idealisierten und stationären Messungen bestimmt wurden. Dynamische Einflüsse wie Windgeschwindigkeiten, Temperatur, Veränderungen der Beiwerte oder die Berücksichtigung der genauen Masse lassen sich nur durch genaue Schätzverfahren der Fahrwiderstandsparameter bestimmen. Unterschiedliche onlinefähige Verfahren sind in [143] [144] [72] vorgestellt.

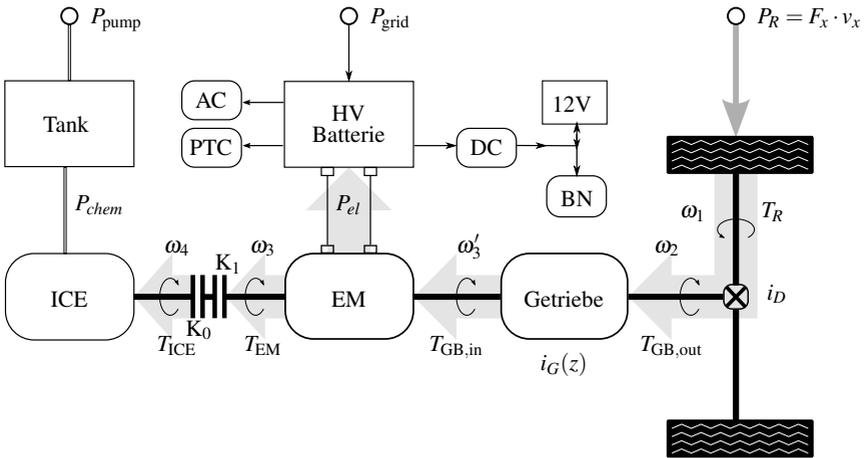


Abb. 2.4.: Nicht-kausaler Leistungsfluss (grau) und Komponenten eines Parallelen Antriebsstrangs (P2) in einem Plug-in Hybridfahrzeug

2.2.2. Modellierung des Leistungsflusses im Fahrzeug

In Abb. 2.4 sind alle betrachteten Komponenten im Leistungsfluss für einen quasistationären Modellierungsansatz mit grauen Pfeilen eingezeichnet. Die Raddrehzahl ω_1 wird über das Übersetzungsverhältnis am Differential i_D zur Getriebeausgangsdrehzahl ω_2 bestimmt. Im quasistationären Ansatz wird der Drehmomentenwandler nicht berücksichtigt bzw. zur Getriebeeinheit gerechnet. Die Getriebeeingangsdrehzahl ω_3 liegt an der Elektromaschine (EM) an. Bei geschlossener Kupplung ist die Motoreingangsdrehzahl ω_4 gleich ω_3 . Die elektrische Flussrichtung im Hochvolt- (HV) und Niedervolt- (12V) Netz ist mit kleinen Pfeilen dargestellt.

Im HV-Netz sind neben der extern nachladbaren HV-Batterie eine Heizung¹⁶ (PTC), der Kompressor der Klimaanlage¹⁷ (AC) und ein DC-DC-Wandler (DC) zum 12V-Netz vorhanden. Das Bordnetz (BN) wird über eine 12 Volt Batterie (12V) gestützt. Beide können auch über den DC-DC-Wandler vom HV-Netz nachgeladen bzw. unterstützt werden. Beim Rekuperieren wird das Bordnetz direkt über den DC-DC-Wandler versorgt. Dies wird Bordnetzrekuperation genannt.

Wirkungsgrade

Die Wirkungsgrade der einzelnen Komponenten haben entscheidenden Einfluss darauf, wie die Energie im Gesamtsystem umgesetzt wird. Die Vorzeichen sind im Folgenden so definiert, dass ein positives Vorzeichen eine eingehende Energie und ein negatives Vorzeichen eine ausgehende Energie beschreibt. So stehen positive Ströme I_{Bat} für ein Laden der Batterie und negative Ströme für ein Entladen.

Verbrennungsmotor: Wie in Abb. 2.4 dargestellt, wird aus den Eingangsgrößen Motordrehzahl ω_4 und Motormoment T_{ICE} die Ausgangsgröße chemischen Leistung P_{chem} berechnet. Der thermodynamische Wirkungsgrad des Verbrennungsmotors lässt sich nach [68] definieren als Funktion der beiden Eingangsgrößen:

$$\eta_{\text{ICE}}(\omega_4, T_{\text{ICE}}) = \frac{\omega_4 \cdot T_{\text{ICE}}}{P_{\text{chem}}} = \frac{\omega_4 \cdot T_{\text{ICE}}}{\dot{m}_f \cdot H_u}$$

Die chemische Leistung ist das Produkt aus dem Massenstrom \dot{m}_f und dem unteren Heizwert des Kraftstoffs H_u . Die charakteristisch konvexe Form eines Effizienzkennfelds eines Verbrennungsmotors ist in Abb. 2.5 (links) zu sehen. Die Volllastkurve definiert das maximal mögliche Moment $T_{\text{max}}(\omega)$ über den Drehzahlbereich. Die wirkungsgradoptimalen Betriebspunkte über alle Drehzahlen sind eingezeichnet. Die zugrunde liegenden Stundenverbräuche $\dot{m}_f(\omega, T)$ sind durch Messdaten gestützt und in einem Kennfeld abgelegt. Eine andere Möglichkeit bietet die Darstellung über dem effektiven Mitteldruck in Form der Willans Beschreibung [68], die hier nicht verwendet wird.

Getriebe: Bei der Drehzahl- und Drehmomentenwandlung im Getriebe entstehen Verluste unterschiedlicher Art [60]. Auf einem Getriebeprüfstand können diese Verluste $T_{\text{GB,loss}}(\omega_3, T_{\text{GB,in}}, z, \tau)$ bei unterschiedlichen Temperaturen τ durch Variation der Gänge z und des Getriebeeingangsmoments $T_{\text{GB,in}}$ über der Drehzahl ω_3 gemessen werden. Der Wirkungsgrad des Getriebes ist wie folgt definiert:

$$\eta_{\text{GB}}(\omega_3, T_{\text{GB,in}}, z, \tau) = \frac{i_G(z) \cdot T_{\text{GB,in}} - i_G(z) \cdot T_{\text{GB,loss}}(\omega_3, T_{\text{GB,in}}, z, \tau)}{i_G(z) \cdot T_{\text{GB,in}}} \quad (2.24)$$

¹⁶ engl. Positive Temperature Coefficient

¹⁷ engl. Air Conditioner

Verluste, die in der Kupplung bei Anfahrvorgängen entstehen, werden im quasistationären Ansatz vernachlässigt. Diese dynamischen Vorgänge werden in Abschnitt 2.2.4 untersucht.

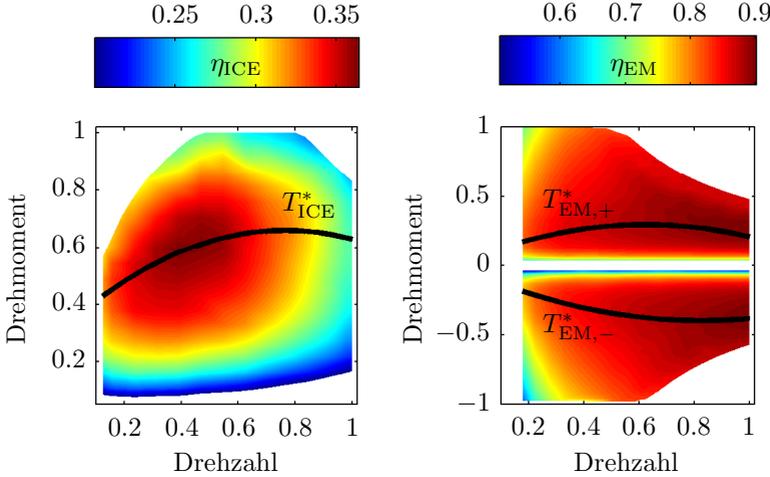


Abb. 2.5.: Normierte Wirkungsgrade des Verbrennungsmotors und der E-Maschine mit optimalen Betriebspunkten über der Drehzahl

Der Wirkungsgrad im Hinterachsgetriebe und den Lagern wird zusammengefasst als konstant angenommen:

$$\eta_{\text{rest}} = \text{const.} \quad (2.25)$$

E-Maschine und Leistungselektronik: Die E-Maschine wird zusammen mit der Leistungselektronik auf einem Prüfstand für negative Momente $T_{\text{EM}} < 0$ (charge¹⁸ und positive Momente $T_{\text{EM}} > 0$ (discharge) vermessen. Aus den gemessenen Verlustleistungen $P_{\text{EM,loss}}$ lässt sich der Wirkungsgrad der beiden Komponenten bestimmen:

$$\eta_{\text{EM}} = \left(\frac{\omega_3 \cdot T_{\text{EM}} + (\text{ch} \cdot P_{\text{EM,loss}})}{\omega_3 \cdot T_{\text{EM}}} \right)^{\text{ch}}, \quad \text{für ch} = \begin{cases} 1, & T_{\text{EM}} < 0 \\ -1, & T_{\text{EM}} > 0 \end{cases}$$

¹⁸ Das Vorzeichen und somit die Begriffe *charge* und *discharge*) beziehen sich auf die Batterie

Bei der Validierung im Fahrzeug ist die elektrische Leistung messbar. Der Wirkungsgrad lässt sich dann über die gemessene Spannung U_{EM} und dem Strom I_{EM} berechnen.

$$\eta_{EM} = \left(\frac{U_{EM} \cdot I_{EM}}{\omega_3 \cdot T_{EM}} \right)^{ch}, \text{ für } ch = \begin{cases} 1, T_{EM} < 0 \\ -1, T_{EM} > 0 \end{cases} \quad (2.26)$$

In Abb. 2.5 (rechts) ist das Wirkungsgradkennfeld einer permanenterrregten Synchronmaschine (PSM) mit Leistungselektronik normiert dargestellt.

HV-Batterie: Die Hochvolt-Batterie lässt sich nach [68] durch ein Ersatzschaltbild beschreiben. Im quasistationären Fall wird die Batterie durch eine ideale Spannungsquelle in Reihe mit einem Innenwiderstand R_i dargestellt. Nach dem KIRCHHOFFSchen Gesetz der Maschenregel lässt sich folgende Gleichung formulieren:

$$U_{HV} = U_{oc}(t) - R_i(t) \cdot I_B(t), \quad (2.27)$$

wobei U_{HV} die Klemmenspannung der Batterie, U_{oc} die Leerlaufspannung und I_B den durch die Batterie fließenden Strom darstellt. Mit der Batterieleistung $P_{Bat} = U_{HV} \cdot I_B$ kann die entstehende quadratische Gleichung nach U_{HV} aufgelöst werden.

$$U_{HV} = \frac{U_{oc}(t)}{2} \pm \sqrt{\frac{U_{oc}^2(t)}{4} - P_{Bat}(t) \cdot R_i(t)} \quad (2.28)$$

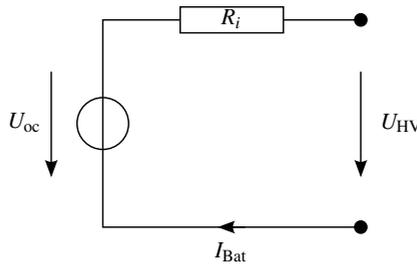


Abb. 2.6.: Ersatzschaltbild einer quasistationär modellierten Batterie

Für die separate Betrachtung der Lade- und Entladevorgänge wird der lokale Wirkungsgrad der Batterie für den aktuellen Arbeitspunkt herangezogen:

$$\eta_{Bat} = \left(\frac{U_{oc}}{U_{HV}} \right)^{ch} = \left(\frac{U_{oc}}{\frac{U_{oc}(t)}{2} + \sqrt{\frac{U_{oc}^2(t)}{4} - P_{Bat}(t) \cdot R_i(t)}} \right)^{ch} \quad (2.29)$$

$$\text{für } ch = \begin{cases} 1, I_{Bat} > 0 \\ -1, I_{Bat} < 0 \end{cases}$$

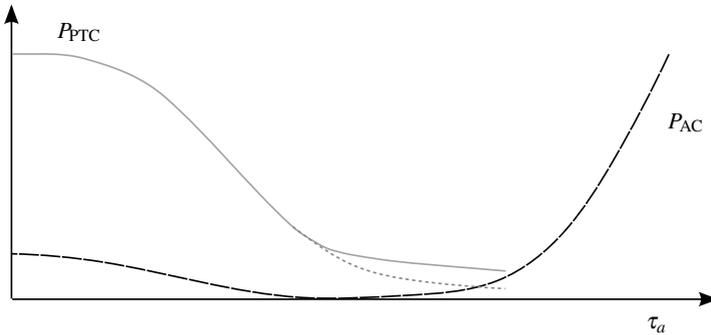


Abb. 2.7.: Leistungsanforderung der Klimaanlage (AC) und der PTC-Heizung über die Außentemperatur τ_a nach [180]

Der Entladestrom bzw. die Entladeleistung ist durch $\eta_{\text{Bat}} \geq 0$ begrenzt. Die Spannungen bewegen sich im Betrieb um die Leerlaufspannung $U_{\text{HV}} \in (U_{\text{HV,min}}, U_{\text{HV,max}})$, wodurch nach [68] die folgenden Grenzen festgelegt werden können:

$$I_{\text{Bat}} \in \left(-\frac{U_{\text{oc}}(t) - U_{\text{HV,min}}}{R_i(t)}, \frac{U_{\text{HV,max}} - U_{\text{oc}}(t)}{R_i(t)} \right) \quad (2.30)$$

$$P_{\text{Bat}} \in \left(-\frac{U_{\text{oc}}^2(t)}{4 \cdot R_i(t)}, \frac{U_{\text{HV,max}}^2 - U_{\text{oc}}(t) \cdot U_{\text{HV,max}}}{R_i(t)} \right)$$

Elektrische Verbraucher: Wie in Abb. 2.4 gezeigt, befinden sich im HV-Netz elektrische Verbraucher, die zusätzlich zur geforderten Leistung der E-Maschine P_{el} einen Leistungsbedarf $P_{\text{el,v}}$ darstellen. Liegen für diese Komponenten Modelle vor, die für die Prädiktion geeignet sind, können diese in die Optimierung einfließen. In dieser Arbeit setzt sich der Leistungsbedarf $P_{\text{el,v}}$ aus drei Komponenten zusammen: Der Leistung für das Bordnetz P_{BN} , der Leistung für eine PTC-Heizung P_{PTC} und der Leistung für den Kompressor der Klimaanlage P_{AC} .

Die Leistungen der Klimaanlage und der PTC-Heizung sind im Wesentlichen von der Außentemperatur τ_a abhängig, was in Abb. 2.7 qualitativ für eine konstante Innentemperatur dargestellt ist.

Um die Luftfeuchtigkeit aus der angesaugten Außenluft zu reduzieren, wird im sogenannten *Reheat-Bereich* die Luft zuerst gekühlt und dann erhitzt.

Der Leistungsbedarf der elektrischen Verbraucher kann unterschiedlich groß ausfallen, weswegen eine Einbindung in ein prädiktives Energiemanagement sinnvoll ist. Über eine bidirektionale Schnittstelle kann der Leistungsbedarf besser abgeschätzt werden. Sie ermöglicht außerdem das gezielte Steuern der Komponenten.

In der vorliegenden Arbeit wurde im Fahrzeugmodell eine Schnittstelle zu den Komponenten vorbereitet.

2.2.3. Zustände eines parallelen Hybridantriebsstrangs

Die Topologie entscheidet, welche Zustände ein Hybridfahrzeug annehmen kann. Diese hybriden Zustände werden auch Hybridmodi bezeichnet. In einem parallelen HEV werden in der Regel fünf Hybridmodi gewählt [12][162][54]:

1. Verbrennungsmotorische Fahrt (H3)
2. Elektrisches Fahren (H1)
3. Lastpunktanhebung (LPV) und -absenkung (Boost) (H9, H0)
4. Rekuperation von Bremsenergie (H10)
5. Segeln¹⁹ (H4)

Betrachtet man alle kombinatorischen Möglichkeiten aus Sicht einer Momentenaufteilung, lassen sich nach [180] 12 Bereiche in einem Zustandsraum definieren, der über das Verbrennungsmotormoment T_{ICE} und dem Moment der E-Maschine T_{EM} aufgespannt ist (siehe Abb. 2.8). Dabei werden zum Beispiel dem Moment zur Erhaltung des Bordnetzbedarfs $T_{EM,BN}$ drei Modi zugewiesen (H6, H7, H8).

Der Verbrennungsmotor kann im Schub betrieben ein Schubmoment $T_{ICE,thrust}$ stellen, wodurch unterschiedliche Verzögerungsverhalten ohne die mechanische Bremse möglich sind (H8). Neben der Bordnetzrekuperation (H7) mit dem negativen Moment $T_{EM,BN}$ lassen sich Ladestrategien umsetzen (H6 und H7), bei denen mit einem negativen Moment $T_{EM,rec}$ die HV-Batterie aufgeladen wird. Nicht jeder Modus ist in einem parallelen Hybridfahrzeug praktisch umsetzbar, wird aber in theoretische Betrachtungen einbezogen.

Die in Abb. 2.8 eingezeichneten Hybridmodi nehmen eine unterschiedliche Größe im Zustandsraum ein. Deren Dimension (Punkt - 0D, Gerade - 1D und Fläche 2D) kann als Maß für den Freiheitsgrad bei der Aufteilung des gesamten Antriebsmoments T_{ges} zwischen Verbrennungsmotor und E-Maschine gewertet werden [180].

Optimale Momentenaufteilung: Die Hybridmodi mit dem größten Freiheitsgrad sind Bereiche, in denen beide Aggregate zum Gesamtmoment beitragen. Sie unterscheiden sich in der Leistungsrichtung der E-Maschine. Bei positivem Moment T_{EM} wird der Verbrennungsmotor unterstützt, was bei starken Beschleunigungsphasen zu einem größeren verfügbaren Moment beiträgt und auch als Lastpunktabenkung bezeichnet werden kann (H0).

Ein negatives E-Maschinenmoment wird zur Vermeidung eines Teillastbetriebs des Verbrennungsmotors bei kleinen Momentenanforderungen eingesetzt (Lastpunktanhebung, H9). Das zusätzliche Moment erhöht den Wirkungsgrad η_{ICE} bei gleichzeitigem Laden der Batterie.

¹⁹ Die kinetische Energie wird allein zur Fortbewegung genutzt.

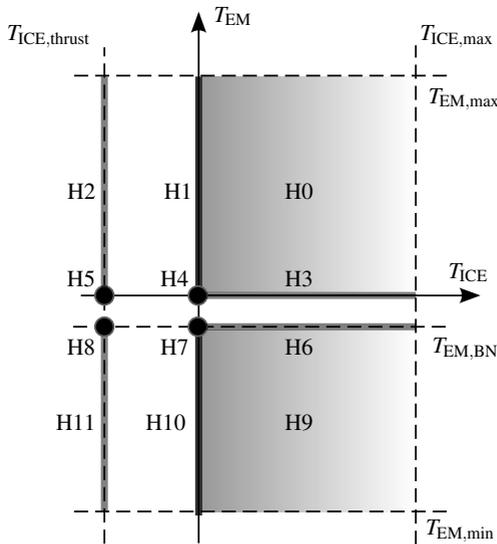


Abb. 2.8.: Hybridmodi (H-) im Momentenzustandsraum des Verbrennermomentes T_{ICE} und dem Moment der E-Maschine T_{EM} [180]

Tab. 2.2.: Berechnung des Gesamtmoments T_{ges} je Hybridmodus H

	$T_{EM} > 0$	$T_{EM} = 0$	$T_{EM} < 0$	$T_{EM} < 0$
$T_{ICE} > 0$	H0 $+T_{EM}$ $+T_{ICE}$	H3 $+T_{ICE}$	H6 $+T_{ICE}$ $-T_{EM,BN}$	H9 $+T_{ICE}$ $-T_{EM,BN}$ $-T_{EM,rec}$
$T_{ICE} = 0$	H1 $+T_{EM}$	H4 0	H7 $-T_{EM,BN}$	H10 $-T_{EM,BN}$ $-T_{EM,rec}$
$T_{ICE} < 0$	H2 $+T_{EM}$ $-T_{ICE,thrust}$	H5 $-T_{ICE,thrust}$	H8 $-T_{ICE,thrust}$ $-T_{EM,BN}$	H11 $-T_{ICE,thrust}$ $-T_{EM,BN}$ $-T_{EM,rec}$

FLECKNER [54] berücksichtigt in einem heuristischen Ansatz den Wirkungsgrad des gesamten Antriebsstrangs zur Auslegung einer optimalen und bedarfsorientierten Momentenaufteilung. Für jedes Gesamtmoment werden je nach Lade- oder Entladeanforderung optimale Kennfelder berechnet, auf deren Basis nachher das Energiemanagement Entscheidungen über die Momentenaufteilung trifft.

In ähnlicher Weise wird in dieser Arbeit der Wirkungsgrad des Antriebsstrangs unter anderem zur Auswahl einer geeigneten Momentenaufteilung herangezogen. Ist q der verbrennungsmotorische Anteil des Gesamtmoments, so lässt sich in H_0 das Gesamtmoment wie folgt aufteilen:

$$T_{\text{ges}} = \frac{T_{\text{ICE}}}{q} = \frac{T_{\text{EM}}}{1-q} \quad (2.31)$$

Eine optimale Momentenaufteilung $q_{H_0}^*$ erfolgt, wenn minimale Energien eingesetzt werden und dadurch folgende Gleichung minimiert wird:

$$q_{H_0}^* = \min_{\eta} \left(\frac{q}{\eta_{\text{ICE}}(\omega_3, T_{\text{ICE}})} + \frac{1-q}{\eta_{\text{EL}}(\text{SoC}, \omega_3, T_{\text{EM}}, P_{\text{EL}})} \right) \quad (2.32)$$

Dabei ist η_{EL} der Wirkungsgrad aller elektrischen Komponenten als Quotient aus mechanischer Leistung und elektrischer Leistung und hängt vom aktuellen SoC, dem Moment der E-Maschine T_{EM} und der Drehzahl ω_3 sowie der Leistung aller elektrischen Verbraucher $P_{\text{EL}} = P_{\text{AC}} + P_{\text{PTC}} + \frac{P_{\text{BN}}}{\eta_{\text{DC}}}$ ab.

SCHLEGEL [180] schlägt eine weitere Gewichtung der Energiequellen vor, indem die aktuellen Strom- und Kraftstoffpreise in Form von spezifischen Kosten pro Energie (Einheit $\frac{\text{Cent}}{J}$) mit aufgenommen werden.

Die Optimierung ist sehr rechenintensiv, weswegen sie offline durchgeführt und in Form von mehrdimensionalen Kennfeldern im Fahrzeugmodell abgelegt wird. Während einer online Optimierung sind so die optimalen Momentenaufteilungen durch eine schnelle Interpolation in diesen Kennfeldern verfügbar.

Für die Modi H6 und H9 werden Momentenaufteilungen vorgenommen, die immer zu einem wirkungsgradoptimalen Betriebspunkt des Verbrennungsmotors führen.

Energiekostenindikator (EKI): Der EKI erlaubt eine Bewertung der elektrischen Energie im Vergleich zur chemischen Energie für einen Fahrzyklus. Dafür wird die Kraftstoffmenge $\dot{m}_{f,\text{LPV}}$ bestimmt, die für das Aufladen der Batterie durch Lastpunktverschiebung notwendig ist:

$$\dot{m}_{f,\text{LPV}} = \frac{T_{\text{ICE}} \cdot \omega_4}{\eta_{\text{ICE}}(T_{\text{ICE}}, \omega_4) \cdot H_u} - \frac{T_{\text{GB,in}} \cdot \omega_3}{\eta_{\text{ICE}}(T_{\text{GB,in}}, \omega_3) \cdot H_u} \quad (2.33)$$

Der EKI ist die durch Lastpunktverschiebung investierte chemische Energie im Verhältnis zur generierten elektrischen Energie [54]:

$$\text{EKI} = \frac{\int \left(\dot{m}_{f,LPV} \cdot \left(1 - \frac{P_{BN}}{P_{EM}} \right) \right) dt}{\int P_{Bat} dt} \quad (2.34)$$

Die Einheit des EKI ist Liter pro kWh (l/kWh). Dieser kann je nach Fahrzyklus und Regelung des Energiemanagements variieren. Durch eine wirkungsgradoptimale Strategie sinkt der EKI, wodurch er als Gütemaß herangezogen werden kann.

2.2.4. Dynamische Vorgänge im Antriebsstrang

Es treten dynamische Zustandsübergänge auf, die Auswirkungen auf die Energiemanagementstrategie im Fahrzeug haben und deshalb für die Optimierung zu modellieren sind. Dazu zählen bei konventionellen Fahrzeugen alle Vorgänge im Schaltgetriebe (Schaltungen, Ein- und Auskuppeln) [138]. Beim hybriden Antriebsstrang werden beim Wechsel der Hybridmodi zusätzlich Energien umgesetzt. Ein nicht zu vernachlässigender Vorgang ist dabei der Start des Verbrennungsmotors.

Energiebedarf beim Verbrennungsmotorwiederstart

Wird der Verbrennungsmotor aus dem Stillstand gestartet, ist neben der chemischen Energie (applizierte Einspritzmenge) auch elektrische Energie aus der E-Maschine notwendig, um die Drehzahlen von Verbrennungsmotor ω_4 und E-Maschine ω_3 zu synchronisieren.

In der Topologie der betrachteten Versuchsfahrzeuge werden zwei Typen des Wiederstartvorgangs unterschieden [160]:

- Anreissstart: Startverhalten bei Drehzahlen oberhalb einer Drehzahlschwelle und Schwellwert/Gradient des Fahrpedals.
- Schlupfstart: Startverhalten bei niedrigen Drehzahlen um das Anbinden des Motors ohne Momenteneinbrüche zu gewährleisten.

In Abb. 2.9 sind die beiden Wiederstart-Typen schematisch abgebildet. Dabei wird der Startvorgang in 5 Phasen unterteilt [178]:

In Phase 1 wird die Überbrückungskupplung des Wandlers geöffnet, sodass sich ein ausreichend großer Schlupf einstellt und die Freigabe zum Schließen der Trennkupplung erteilt wird. In Phase 2 wird die Trennkupplung (K_0) nur soweit geschlossen, dass genügend Drehmoment anliegt, um den Verbrennungsmotor anzudrehen. Die Drehzahl des Verbrennungsmotors ω_4 steigt nach Einleiten der Phase 2 an. Das Drehmoment liegt an der Trennkupplung solange an, bis eine ausreichende Drehzahl erreicht wird, bei der eine Einspritzung freigegeben werden kann.

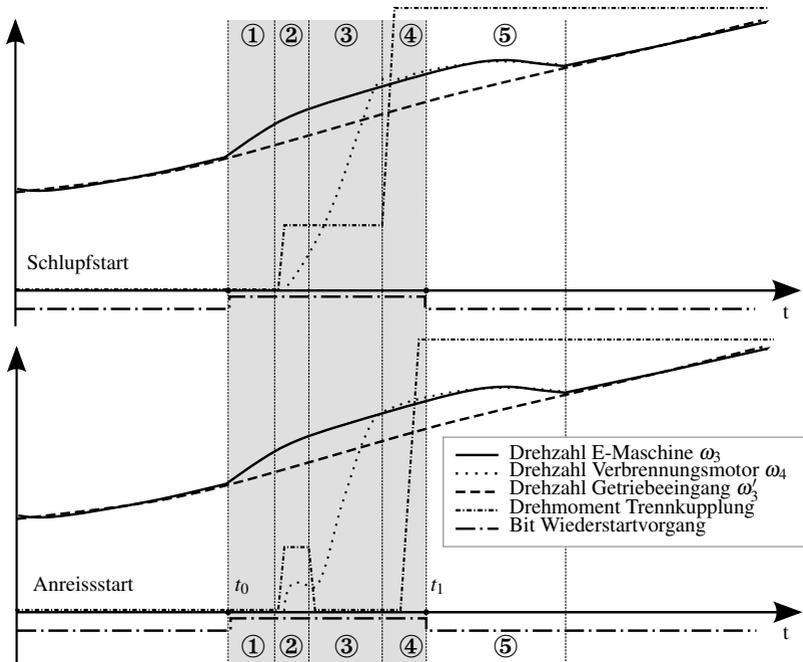


Abb. 2.9.: Schematische Darstellung der Wiederstartvorgänge nach Phasen und Typ (Schlupf- und Anreissstart) nach [158]

In Phase 3 unterscheiden sich die beiden Wiederstart-Typen. Beim *Anreissstart* wird die Trennkupplung wieder geöffnet, wodurch die Drehzahl ω_4 kurzzeitig durch das Wegfallen des Drehmoments der Trennkupplung einbricht. Beim *Schlupfstart* wird das Moment an der Trennkupplung während des Einspritzvorgangs konstant gehalten. Ein Drehzahleinbruch des Verbrennungsmotors wird dadurch vermieden. Nach Phase 4 kommt es in Folge einer geschlossenen Kupplung zum Kraftschluss zwischen den beiden Aggregaten. In Phase 5 wird die Kupplung der Wandlerüberbrückung (K_1) wieder geschlossen, wodurch der Wiederstartvorgang endet.

Modellbildung: In der Arbeit von LABONTE [178] wurde auf Basis von Messdaten die Regelung eines dynamischen Modells zur Simulation des Wiederstart-Verhaltens des Verbrennungsmotors angepasst. Dabei wurde der Wiederstartvorgang auf die Phasen 1 bis 4 begrenzt, da in Phase 5 Schaltvorgänge möglich sind. Die dafür notwendige Zeit $t_{wstr} = t_1 - t_0$ ist in Abb. 2.9 eingezeichnet. Die Modellierung wurde aufgrund einer Verwendung in der Optimierung mit drei Zielen ausgelegt:

Die Bestimmung der chemischen Energie E_{chem} , der elektrischen Energie E_{el} sowie der benötigten Zeit t_{wstt} für einen Wiederstartvorgang. Die chemische Energie für einen Wiederstartvorgang lässt sich wie folgt bestimmen:

$$E_{\text{chem}} = \left(m_{f,\text{inj}} + \int_{t_0}^{t_1} \dot{m}_f(T_{\text{ICE}}, \omega_4) \cdot dt \right) \cdot H_u, \quad (2.35)$$

wobei $m_{f,\text{inj}} = k \cdot m_{\text{inj}}$ die eingespritzte Kraftstoffmenge bis zur Leerlaufdrehzahl darstellt, die sich aus der Anzahl der Einspritzungen k und der Einspritzmenge m_{inj} zusammensetzt. Der Kraftstoffmassenstrom $\dot{m}_f(T_{\text{ICE}}, \omega_4)$ ist als Kennfeld über der Motordrehzahl ω_4 und dem Motormoment T_{ICE} abgeleitet.

Die elektrische Energie für einen Wiederstartvorgang ist die Differenz aus der gesamten elektrischen Energie $E_{\text{el,ges}}$ und der Energie $E_{\text{el,des}}$, die bei einem geforderten Moment T_{des} (Kupplungssollmoment) benötigt wird:

$$E_{\text{el}} = E_{\text{el,ges}} - E_{\text{el,des}} \quad (2.36)$$

Dabei werden $E_{\text{el,ges}}$ und $E_{\text{el,des}}$ wie folgt definiert:

$$E_{\text{el,ges}} = \int_{t_0}^{t_1} \eta_{\text{Bat}}(T_{\text{EM}}, \omega_3) \cdot \eta_{\text{EM}}(T_{\text{EM}}, \omega_3) \cdot T_{\text{EM}}(t) \cdot \omega_3(t) \cdot dt \quad (2.37)$$

$$E_{\text{el,des}} = \int_{t_0}^{t_1} \eta_{\text{Bat}}(T_{\text{des}}, \omega_3) \cdot \eta_{\text{EM}}(T_{\text{des}}, \omega_3) \cdot T_{\text{des}}(t) \cdot \omega_3(t) \cdot dt \quad (2.38)$$

Modellrestriktion durch Forderung nach Präzisierung: Ein Fahrzeugmodell, das für die Prädiktion geeignet ist, beinhaltet als Eingangsgrößen nur Zustandsgrößen entlang einer Strecke oder Größen, die aus einem aktuellen Fahrzeugszustand bestimmt werden können. Durch diese Restriktion wird ein prädiktives Fahrzeugmodell auf wenige Eingangsgrößen beschränkt, wodurch auch nur eine begrenzte Genauigkeit erreicht werden kann.

Im Rahmen einer Sensitivitätsanalyse auf Basis einer DoE²⁰ Versuchsplanung wurden in [178] die relevanten Einflussgrößen für den Energiebedarf bei einem Wiederstart bestimmt. Die folgenden Eingangsgrößen erfüllen die Forderung nach Präzisierung:

- Art des Starts (Schlupf/Anreiss)
- Getriebeeingangsdrehzahl ω'_3
- Kupplungssollmoment T_{des}

²⁰ engl. Design of Experiments

Regressionsmodell: Es wird ein Modell für den Wiederstartvorgang mittels einer linearen Regression gebildet, deren Parameter für die beiden Wiederstarttypen getrennt bestimmt werden. Dabei lässt sich die chemische Energie nach [178] durch ein Polynom 2. Ordnung abbilden, das allein von der Drehzahl abhängt:

$$\hat{E}_{\text{chem}}(\omega_3) = a_0 + a_{10} \cdot \omega_3 + a_{20} \cdot \omega_3^2 \quad (2.39)$$

Dies lässt sich dadurch begründen, dass sich $E_{\text{chem}} = E_{m,\text{kin}} + E_{m,\text{th}}$ als Summe aus der kinetischen Energie $E_{m,\text{kin}}$ für den Drehzahlaufbau und der thermischen Energie $E_{m,\text{th}}$ aufgrund der Verlustleistung in der Kupplung beim Wiederstart bestimmen lässt, die beide proportional zur Drehzahl im Quadrat sind ($E_{\text{chem}} \sim \omega_3^2$).

Beim elektrischen Energiebedarf kommt zur Drehzahl als weiterer Freiheitsgrad das geforderte Wunschkmoment T_{des} hinzu, sodass das Regressionsmodell für die elektrische Energie beim Wiederstart wie folgt lautet:

$$\hat{E}_{\text{el}}(\omega_3, T_{\text{des}}) = b_0 + b_{10} \cdot \omega_3 + b_{01} \cdot T_{\text{des}} + b_{20} \cdot \omega_3^2 + b_{11} \cdot \omega_3 \cdot T_{\text{des}} \quad (2.40)$$

Die Zeit eines Wiederstartvorgangs wird als quadratische Funktion über der Drehzahl abgebildet:

$$\hat{t}_{\text{wstr}} = c_0 + c_{10} \cdot \omega_3 + c_{20} \cdot \omega_3^2 \quad (2.41)$$

In Abb. 2.10 sind Regressionsmodelle der einzelnen Arten des Wiederstarts und Energieanforderungen dargestellt. Das Modell ist je nach Ordnung als Kurve oder Fläche abgebildet. Die modellierten Energien korrelieren sehr gut mit den simulierten Werten ($R^2 > 0,99$), während bei der Zeitberechnung deutliche Ausreißer zu beobachten sind, die sich negativ auf die Güte des Modells auswirken.

2.3. Validierung des Fahrzeugmodells

Exemplarisch werden einzelne Funktionen aus dem Fahrzeugmodell auf ihre Genauigkeit und Reproduzierbarkeit überprüft, indem sie anhand von Messungen validiert werden. Diese Messungen wurden in Versuchsfahrzeugen auf einem Realzyklus (Stuttgart-Runde, siehe Abschnitt 3.4.2) in zwei Messfahrten aufgenommen und beinhalten Signale aus dem CAN²¹-Bus, die sowohl Messwerte aus der Fahrzeugsensorik, als auch zum Teil berechnete Werte aus Steuergeräten darstellen. Die Aufzeichnungen beinhalten 126 km Fahrstrecke und sind in Messabschnitte mit je zwei Minuten Länge aufgeteilt.

Die untersuchten Testfälle dienen der Validierung der Funktionen im Fahrzeugmodell zur Berechnung bestimmter Größen. Da diese Größen aus mehreren Eingangsgrößen bestimmt werden, können die Funktionen als MISO²²-Systeme aufgefasst werden.

²¹ Controller Area Network

²² Multiple Input Single Output

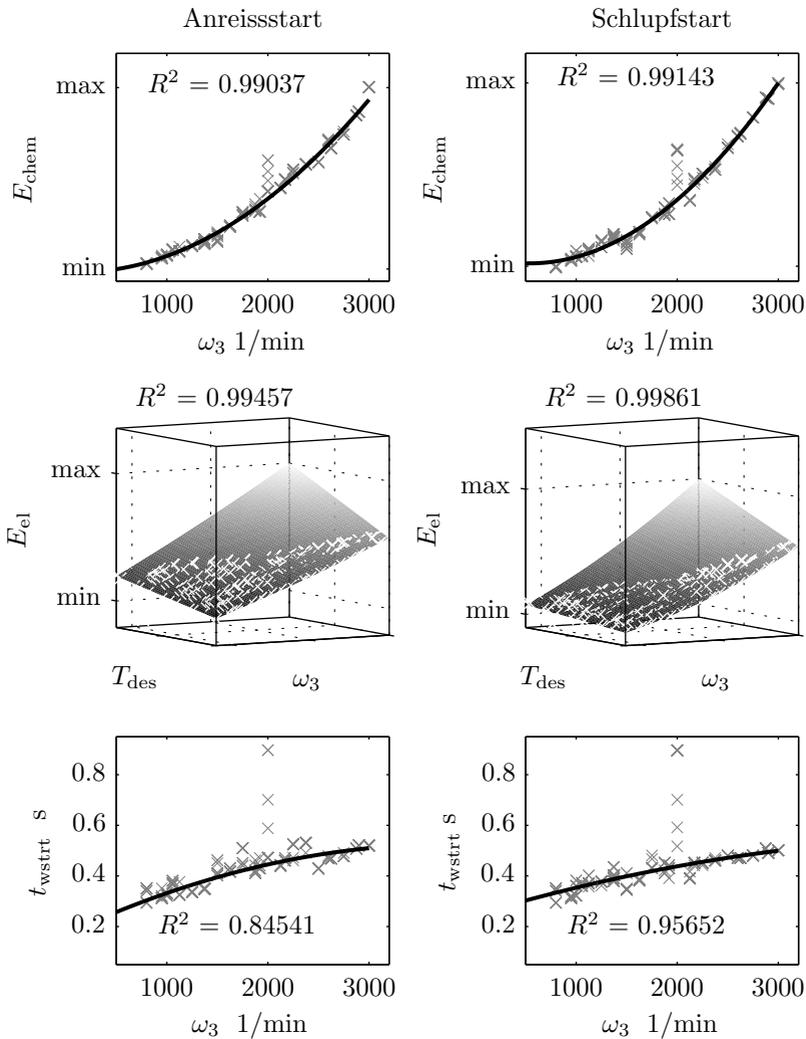


Abb. 2.10.: Polynomiale Regressionsmodelle für die Energieberechnung bei Wiederstartvorgängen unterschieden nach Anreissstart und Schlupfstart nach [178]

Aus mehreren Eingangssignalen wird ein Ausgangssignal erzeugt. In Tab. A.1 sind fünf der Testfälle nach Eingangs- und Ausgangssignal sowie der Frequenz f der zugehörigen CAN-Botschaft aufgelistet. Die Schwankungen der Buslast liegen bei $\pm 3,5\%$ und können in der Validierung vernachlässigt werden [180]. Phasenverschiebungen innerhalb der Signalverarbeitung auf dem CAN sind Teil der Analyse.

In [180] wurde eine ausführliche Residuenanalyse aller Testfälle durchgeführt, um die Güte und Reproduzierbarkeit der Funktionen im Fahrzeugmodell zu gewährleisten sowie systematische Fehler zu identifizieren. Im Rahmen dieser Arbeit sollen die gemessenen und berechneten Ausgangsgrößen anhand des empirischen Korrelationskoeffizienten ρ nach BRAVAIS-PEARSON bewertet werden.

Der empirische Korrelationskoeffizient ρ ist nach [151] definiert als Quotient aus der Kovarianz S_{xy} und dem Produkt der einzelnen Standardabweichungen S_x und S_y .

$$\rho = \frac{S_{xy}}{S_x S_y} = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad (2.42)$$

Dabei stellen \bar{x} und \bar{y} die empirischen Mittelwerte der N Messwerte dar.

$$\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i, \text{ und } \bar{y} = \frac{1}{N} \sum_{i=1}^N y_i \quad (2.43)$$

Das gemessene Signal x ist zum berechneten Signal y positiv korreliert, wenn $\rho > 0$ und negativ korreliert, wenn $\rho < 0$. Je näher $|\rho| = 1$, desto besser stimmen beide Signale überein.

2.3.1. Ausgewählte Testfälle

Das quasi-stationär modellierte Fahrzeugmodell wird für ausgewählte Testfälle bewertet, die den Fahrzeugzustand und im Besonderen einen Zustandsübergang entscheidend beeinflussen. Die Berechnung der Funktionen erfolgt je Messausschnitt ausgehend vom gemessenen Anfangszustand, sodass ein Vergleich der gemessenen und berechneten Signale je Messausschnitt möglich ist. Die Auswahl der Testfälle erfolgt nach folgenden Überlegungen:

Die Geschwindigkeit und der Batterieladezustand definieren maßgeblich den Fahrzeugzustand. Ein Zustandsübergang erfolgt durch eine Fahrzeugbeschleunigung und den Batteriestrom. Die Momentenaufteilung lässt sich durch die Motordrehzahl sowie dem Gesamtmoment und dem Moment eines Aggregats bestimmen. In den ausgewählten Fällen wird deshalb das E-Maschinenmoment betrachtet.

Fahrzeugbeschleunigung

Die Fahrzeugbeschleunigung wird im Fahrzeug direkt über einen Sensor gemessen, dessen Signal durch die Fahrzeugdynamik verfälscht wird. Erst durch eine Nachbearbeitung kann die Beschleunigung im vereinfachten Ansatz des Punktmassenmodells verwendet werden. Im vorliegenden Fall wird das Beschleunigungssignal aus dem Geschwindigkeitssignal bestimmt. In Abb. 2.11 sind für einen Messausschnitt die Beschleunigung des Sensors $a_{x,sens}$, die aus der Geschwindigkeit bestimmte Beschleunigung $a_{x,meas}$ sowie die berechnete Beschleunigung $a_{x,calc}$ exemplarisch dargestellt.

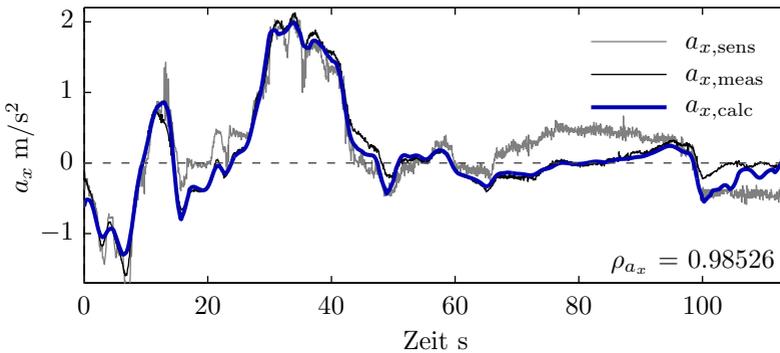


Abb. 2.11.: Fahrzeugbeschleunigung des Sensors $a_{x,sens}$, aus der Geschwindigkeit gemessen $a_{x,meas}$ sowie berechnet $a_{x,calc}$ in einem Messausschnitt nach [180]

Bei betragsmäßig kleinen Beschleunigungen treten vergleichsweise hohe Fehler auf. Der Getriebewirkungsgrad bei kleinen Momenten in hohen Gängen ist mit kleinen Werten hinterlegt. Dadurch wird die Radkraft zu groß berechnet und die Beschleunigung fällt stark negativ aus [180].

Motordrehzahl

Die Motordrehzahl ω_4 entspricht bei geschlossener Kupplung der Getriebeeingangsdrehzahl ω_3' und ist damit die relevante Drehzahl für E-Maschine und Verbrennungsmotor. Sie lässt sich maßgeblich aus der Geschwindigkeit bestimmen und spiegelt durch die Gangübersetzungen die Schaltungen des Getriebes wider. In Abb. 2.12 ist eine Phasenverschiebung der gemessenen Drehzahl $\omega_{4,meas}$ zur berechneten Drehzahl $\omega_{4,calc}$ zu erkennen. Das wird dadurch begründet, dass der Zielgang zur Berechnung verwendet wird, dessen Signalwert eine Sekunde vor dem tatsächlichen Schalten ausgegeben wird. Zustände, in denen die Kupplung des Automatikgetriebes nicht vollständig geschlossen ist, sind grau gekennzeichnet.

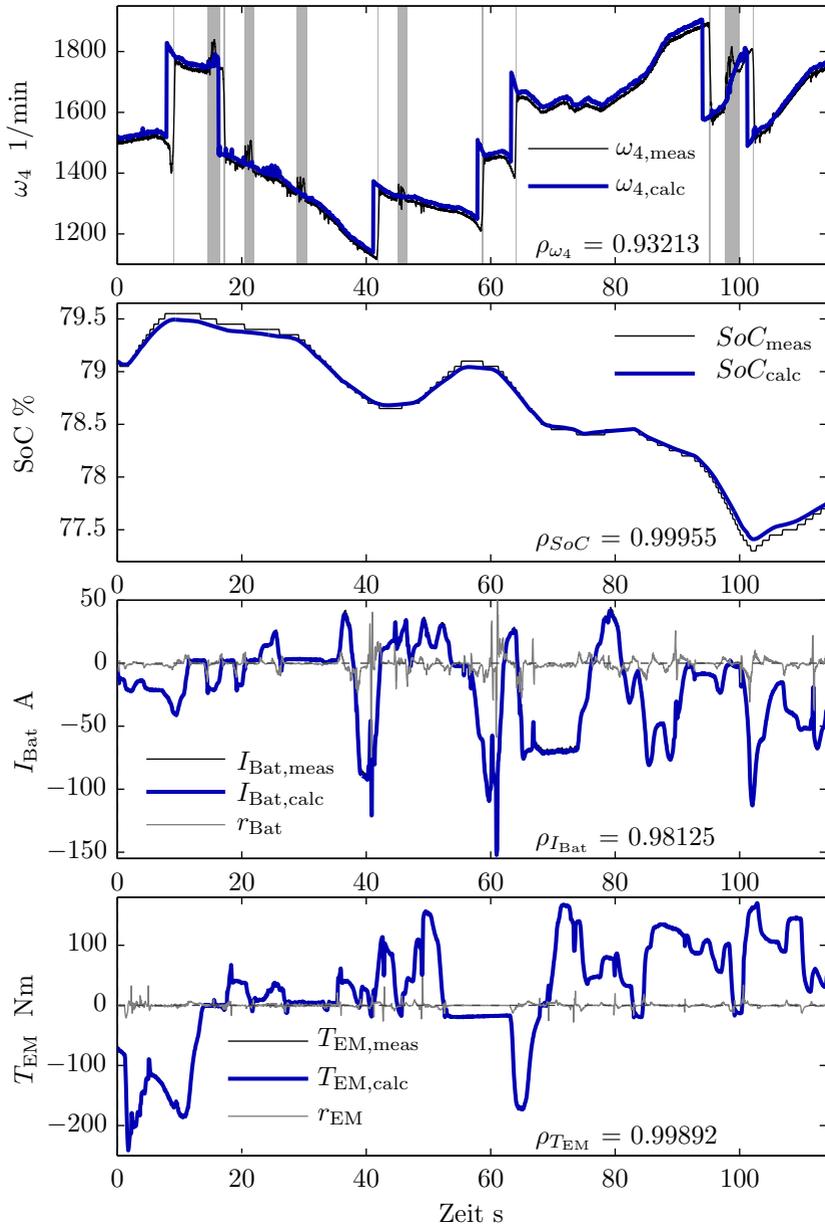


Abb. 2.12.: Gemessene und berechnete Größen auf unterschiedlichen Messausschnitten nach [180]

Die berechnete Drehzahl hat eine systematische Abweichung zu höheren Werten. Das kann mit den Unsicherheiten der Sensorik teilweise begründet werden.

Batterieladezustand

Die quasi-stationäre Modellierung der Batterie bewirkt bei einem dynamischen Lade- und Entladeverhalten einen linearen Drift über der Zeit. Das CAN-Signal spiegelt nicht den tatsächlichen prozentualen Energiegehalt wider, da die Zellspannung der HV-Batterie nur in Ruhephasen zum Kalibrieren des Signals berücksichtigt wird. Da dieses Signal im Fahrzeug entscheidend den Fahrzeugzustand definiert, wird ein Korrekturfaktor ($\approx 0,7$) mit einer im CAN verfügbare Batteriekapazität multipliziert.

Durch einen ausreichend genauen Batteriestrom korrelieren der berechnete SoC_{calc} sehr gut mit dem gemessenen SoC_{meas} . In Abb. 2.12 ist die niedrige Abtastung des CAN-Signals mit einer Frequenz von $f = 10 \text{ Hz}$ zu sehen. Die Regelung des Gesamtsystems erfordert eine genaue Zustandsbestimmung der Batterieladung, die durch die Integration des Batteriestroms zwischen den Abtastzeitpunkten erreicht werden kann.

Batteriestrom

Der berechnete Batteriestrom $I_{\text{Bat,cal}}$ korreliert gut mit dem gemessenen $I_{\text{Bat,meas}}$ (vgl. Beispielausschnitt in Abb. 2.12). Dabei wird in allen Messungen ein Phasenversatz von 0,1 s festgestellt, bei dem der gemessene Strom dem berechneten vorausgeht. Als mögliche Erklärung wird hier angenommen, dass das elektrische Moment als Zielmoment auf dem CAN-Bus angezeigt wird [180]. Die absoluten Fehler r_{Bat} sind vor allem durch den Phasenversatz zu begründen.

Elektrisches Moment

Im Beispielausschnitt für das elektrische Moment T_{EM} in Abb. 2.12 treten bei kurzfristigen Lastspitzen absolute Fehler r_{EM} auf, die aber für die weiteren Betrachtungen zu vernachlässigen sind. Durch eine gute Korrelation der Signale ist eine hinreichend genaue Modellierung der Momentenaufteilung gewährleistet.

In Tab. 2.3 ist der empirische Korrelationskoeffizient ρ für jeden betrachteten Testfall über alle Stichproben N aufgelistet. Die Anzahl der Stichproben variiert, da bei der Modellierung Einschränkungen getroffen werden mussten, die eine Vergleichbarkeit nicht mehr zulassen. Zu diesen Einschränkungen zählen Drehzahl-, Momenten- oder Stromgrenzen.

Tab. 2.3.: Auswertung der einzelnen Testfälle

Testfall	1 (a_s)	2 (α_4)	3 (SoC)	4 (I_{Bat})	5 (T_{EM})
Stichproben N	85 447	140 016	157 237	85 905	141 979
Korr. koef. ρ	0.91538	0.92125	0.99940	0.99820	0.99999
R^2	0.83705	0.814020	0.99861	0.99558	0.99999
RMSE	0.27059	135.733	0.00133	2.49504	0.14528

2.3.2. Fazit

Wie in Tab. 2.3 zu erkennen, sind die betrachteten Funktionen des Fahrzeugmodells durch eine gute Korrelation der Ergebnisse mit den Messsignalen als valide zu betrachten. Die Berechnung des Fahrwiderstands, die in die Beschleunigung einfließt, erweist sich als besonders fehleranfällig. Bei einer Untersuchung der Fahrwiderstandsanteile in [180] macht der Steigungswiderstand F_{St} ein Drittel des Gesamtwiderstands aus. Die Steigung α_s sowie die Fahrzeugmasse m haben somit entscheidenden Einfluss auf die Güte der Prädiktion einer Beschleunigung. Die Steigungsinformation wird aus einer Karte gewonnen, während die Fahrzeugmasse idealerweise während der Fahrt angelernt wird.

3. Betriebsstrategien für Hybridfahrzeuge

Elektronische Steuergeräte²³ (ECU) regeln unterschiedliche Komponenten des Antriebsstrangs in modernen Fahrzeugen. Dabei verarbeiten sie z. B. die Intentionen des Fahrers durch das Einlesen der Fahrpedal- oder Bremspedalstellung sowie des Lenkradwinkels und geben diese an hardwarenahe Steuerungen weiter. Die Signalverarbeitung sowie deren Interpretation können allgemein in Betriebsstrategien zusammengefasst werden.

Betriebsstrategien ermöglichen dem Fahrer, einen immer komplexer werdenden Antriebsstrang zu bedienen. Dabei sind zwei Kategorien zu unterscheiden:

- Fahrstrategien
- Energiemanagementstrategien

Unter Fahrstrategien werden alle Funktionen zusammengefasst, die die Geschwindigkeit beeinflussen und den Fahrer bei der Wahl einer geeigneten Geschwindigkeit unterstützen. Der Fokus liegt hier auf einer primär sicheren und komfortablen Fahrweise. Derzeitige Systeme, die diese Funktionen dem Fahrer anbieten sind z. B. Stabilisations- und Sicherheitssysteme wie das Elektronische Stabilisierungsprogramm (ESP). Aktives Eingreifen in die Längsregelung und damit eine autonome Ausführung der Fahrstrategie ermöglicht z. B. der adaptive Tempomat²⁴ (ACC).

Ist die Sicherheit und Fahrbarkeit im Fahrzeug gewährleistet, können energieeffiziente Fahrstrategien in Kraft treten, die die Energieflüsse im Antriebsstrang gezielt beeinflussen, wodurch der Verbrauch gesenkt werden kann. Als Beispiel sind regeneratives Bremsen und optimale Schaltvorgänge zu nennen.

Energiemanagementsysteme koordinieren als übergeordnete Instanz die Energieflüsse in einem Fahrzeug und sind vor allem bei mehr als einer Energiequelle im Fahrzeug zwingend notwendig. Hybridfahrzeuge sind ohne einfache Energiemanagementsysteme, die die Momenten- oder Leistungsaufteilung steuern, nicht zu bedienen.

Im Folgenden werden Betriebsstrategien vorgestellt, die koordinierende Aufgaben erfüllen und als Schwerpunkt eine energieeffiziente Betriebsweise zum Ziel haben.

²³ engl. Electronic Control Unit

²⁴ engl. Adaptive Cruise Control

3.1. Energieeffiziente Fahrstrategien

Fahrstrategien können nach [64] in drei aufeinanderfolgende Phasen unterteilt werden: Situationserkennung, Strategieauswahl und Strategieausführung.

Situationserkennung

Die Situationserkennung bündelt und interpretiert alle Informationen, die den Fahrzeugzustand, die Umgebung und den Fahrer betreffen. Für energieeffiziente Fahrstrategien wurde schon in frühen Untersuchungen [153, 81] auf die Notwendigkeit der Information über die vorausliegende Strecke, insbesondere ihres Höhenverlaufs, hingewiesen. Die Situationserkennung beinhaltet somit nicht nur aktuelle und zurückliegende Informationen, sondern kann sich durch eine Lokalisierung in ein Verkehrsszenario zeitlich und örtlich einordnen und somit die Strategieauswahl vorbereiten.

Strategieauswahl

In der Strategieauswahl wird auf Basis der erkannten Situation eine Entscheidung getroffen. Die Entscheidungsfindung kann z. B. durch ein Umschalten zwischen Lösungen für bekannte Situationen erfolgen. Dabei werden Beschleunigungs-, Verzögerungs- und Konstantfahrphasen verbrauchsoptimal durchfahren. Bei erhöhter Reisezeit können 10-25 % Kraftstoff im Fahrzeug durch frühzeitiges Ausrollen und Gangschaltvorgänge ohne Momentenreserve eingespart werden [64, 149, 42]. Um auch bei höheren Geschwindigkeiten eine Kraftstoffeinsparung zu erreichen, werden neben den regelbasierten Ansätzen Methoden zur Lösung eines Optimalsteuerungsproblems herangezogen. In [148] werden für numerische Lösungen eines Optimalsteuerungsproblems drei Gruppen unterschieden:

- Dynamische Programmierung (HAMILTON-JACOBI-BELLMAN Gleichung)
- Indirekte Methoden (EULER-LAGRANGE und PONTRYAGIN's Maximumsprinzip)
- Direkte Methoden (Transformation in Nichtlineare Programmierung)

Die ersten beiden Gruppen werden bei der Vorstellung verschiedener Vorgehensweisen zur Strategieoptimierung genauer beschrieben. Ein Vergleich energieeffizienter Fahrstrategien, die auf Basis aller drei hier genannter Methodengruppen berechnet werden, ist in [147] zu finden.

Strategieausführung

Ist eine Strategie ausgewählt, gibt es verschiedene Möglichkeiten diese umzusetzen. In der Kategorie der passiven Fahrerassistenzfunktionen werden dem Fahrer energie-

effiziente Fahrstrategien durch eine Mensch-Maschine-Schnittstelle²⁵ (HMI) angezeigt. Als Beispiel sind optimale Schaltpunktanzeigen [69] oder Beschleunigungs-, bzw. Verzögerungsempfehlungen zu nennen [64, 149, 140, 98].

Eine weitere Ausführungsform sind aktive Fahrerassistenzfunktionen, die Strategien ohne Fahrereingriffe einregeln. Darunter zählen unterschiedliche Formen von vorausschauenden Schaltstrategien, die aufgrund von Kartendaten vor Kurven zurückschalten [83] oder durch Prädiktion des Geschwindigkeitsverlaufs und der zukünftigen Lastanforderung des Motors möglichst hohe Gänge stellen [122, 55].

Die längsgerichtete Strategieausführung in Form eines ACC-Systems stellt die erste Stufe in Richtung des autonomen Fahrens dar.

3.1.1. Fahrerassistenzsysteme mit automatisierter Fahrzeuglängsführung

Aktive Fahrerassistenzsysteme, die neben der vorausschauenden Schaltstrategie eine Geschwindigkeitsstrategie in Form einer Längsregelung umsetzen, verfügen über einen weiteren Freiheitsgrad zur Umsetzung eines energieeffizienten Fahrens. Sie bauen auf das Prinzip von ACC-Systemen auf, deren Regelung durch prädiktive Streckendaten angepasst werden kann.

Ein ACC-System empfängt Informationen über einzelne vorausfahrende Objekte, die je nach Relevanz für das Fahrzeug klassifiziert werden können. Da das Fahrverhalten vorausfahrender Verkehrsteilnehmer sehr vom Straßentyp abhängt, kann die aktuelle Verkehrssituation durch Einbeziehen von Navigationsdaten genauer abgebildet werden. Durch ein Verknüpfen der gemessenen Informationen mit den Karteninformationen lässt sich die Dynamik der ACC Regelung verbessern [28]. Der Fokus der ACC-Systeme liegt primär auf der Sicherheit und der Entlastung des Fahrers.

Bei Lastkraftwagen (LKW) sind vermehrt energieeffiziente Fahrerassistenzsysteme mit einer automatisierten Fahrzeuglängsführung zu finden, da eine Entlastung des Fahrers sowie das große Einsparpotenzial im Kraftstoffverbrauch gerade für Logistikunternehmen von Bedeutung sind [82]. Neben der heuristischen Strategieplanung [93] werden Verfahren der Dynamischen Optimierung für die Lösung des Optimalsteuerungsproblems gewählt. In [77, 76] und [58] wird die Dynamische Programmierung verwendet, um in einem konventionellen Antriebsstrang bei gleicher Fahrzeit 3-4 % Kraftstoffeinsparung zu erlangen. Ein speziell für die komplexe Aufgabenstellung der optimalen Regelung eines LKWs entworfene Optimierungsansatz wird von TERWEN [166] unter dem Namen Integrated Predictive Powertrain Control (IPPC) vorgestellt. Auf Basis direkter Optimierungsmethoden wird eine Kraftstoffeinsparung von 9,4 % bei gesteigerter Durchschnittsgeschwindigkeit zu einem geübten Kraftfahrer und 3 % im Vergleich zu einer Fahrt mit einem konventionellen Tempomat erlangt. Neben der Geschwindigkeitsstrategie werden die Schaltvorgänge optimiert.

²⁵ engl. Human Machine Interface

Das ACC InnoDrive System [138] betrachtet für Sportwagen eine möglichst energieeffiziente Fahrweise durch Optimierung der Fahrstrategie (Geschwindigkeit und Gangwahl). Dabei kann in unterschiedlichen Dynamikstufen selbst bei höheren Durchschnittsgeschwindigkeiten Kraftstoff eingespart werden.

Bei Messungen einer Realfahrt auf einer Überlandrunde liegt das Kraftstoffeinsparpotenzial zwischen 10 und 20 % bei gleicher Durchschnittsgeschwindigkeit.

3.2. Energiemanagementstrategien für Hybridfahrzeuge

Das Energiemanagement in einem parallelen Hybridfahrzeug koordiniert die Momentenaufteilung. Die dafür verwendeten Strategien werden in unterschiedliche Kategorien eingeteilt [68]. Das Wissen über die Strecke entscheidet zwischen kausalen und nicht-kausalen Strategien.

Kausale Strategien agieren als Regler, die nur aktuelle und zurückliegende Informationen für die Entscheidungsfindung zur Verfügung haben. Bei nicht-kausalen Energiemanagementstrategien müssen die Strecke und das Geschwindigkeitsprofil bekannt sein. Streckeninformationen wie Höhendaten werden für eine gegebene Route aus digitalen Streckendaten entnommen. Das Geschwindigkeitsprofil ist durch ein Fahrzyklus festgelegt oder muss anhand der gesetzlichen Geschwindigkeitsbegrenzungen präzisiert werden [12].

Eine weitere Unterscheidung besteht in der Optimalität der verwendeten Strategie. Heuristische Energiemanagementstrategien sind nicht optimal, aber stellen den Stand der Technik in heutigen Hybridfahrzeugen dar [68]. Optimale Strategien werden meist offline in einer Simulation bestimmt und als Referenz für Regler im Fahrzeug verwendet, die wiederum durch vereinfachte Ansätze echtzeitfähig realisiert werden.

3.2.1. Heuristische Energiemanagementstrategien

Eine Heuristik²⁶ ist eine Strategie, mit deren Hilfe sich komplexe Vorgänge vereinfacht beschreiben lassen. Vorteile bestehen in der einfachen und oft intuitiven Umsetzung. Optimale Ergebnisse können mit einer heuristischen Strategie nicht erzielt werden [51].

Bei der Auslegung einer heuristischen Strategie können folgende Prinzipien verfolgt werden:

- Der Verbrennungsmotor läuft nur, wenn er in einem hohen Wirkungsgrad betrieben werden kann.
- Die Batterieladestrategie bewirkt, dass z. B. Grenzen zum Schutz der Batterie nicht unter- oder überschritten werden.

²⁶ altgr.: suchen - finden kann nach [92] mit *zum Finden geeignet* umschrieben werden

- In Warmlaufphasen des Verbrennungsmotors oder Motordiagnosephasen werden Effizienzbetrachtungen nicht berücksichtigt.
- Der Wirkungsgrad des gesamten, quasi-stationär modellierten Antriebsstrangs wird für die Auslegung der Strategie herangezogen.

Zur Umsetzung werden unterschiedliche Ansätze gewählt. In [68] wird zwischen kennfeldbasierten und regelbasierten Ansätzen unterschieden.

Kennfeldbasierte Strategie

Der kennfeldbasierte Ansatz beinhaltet mehrdimensionale Zuweisungstabellen, sogenannte Kennfelder, die für jede betrachtete Situation und Eingangsgröße eine Steuergröße zur Verfügung stellen. In Abb. 3.1 sind Kennfelder, die die Momentenaufteilung u in Abhängigkeit des Fahrerwunschs T_{des} und der Geschwindigkeit v_x für zwei unterschiedliche Zustände der Batterie²⁷ (SoC) festlegen, schematisch dargestellt. Dabei wird zwischen rein verbrennungsmotorischem Betrieb ($u = 0$), rein elektrischem Betrieb ($u = 1$), assistiertem Betrieb / Boost ($0 < u < 1$) und Laden durch Lastpunktabsenkung ($u < 0$) unterschieden.

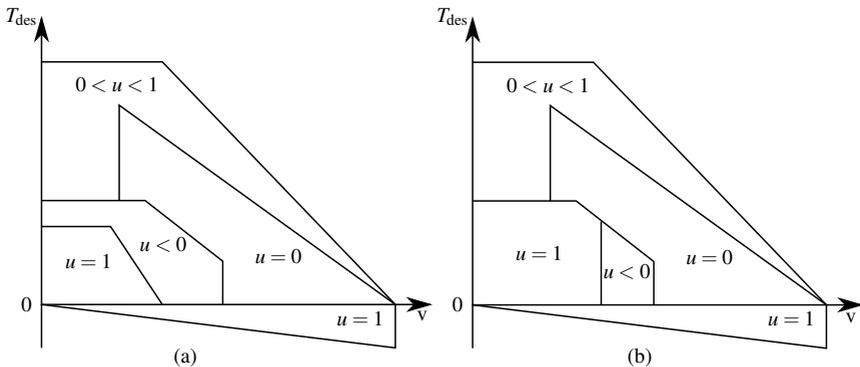


Abb. 3.1.: Kennfeldbasierte, heuristische Energiemanagementstrategie für eine niedrige (a) und volle (b) Batterie nach [68]

Bei einem niedrigen SoC (a) wird der Bereich des rein elektrischen Betriebs kleiner gewählt, als im Vergleich zur vollen Batterie (b). Eine Vielzahl von Anwendungen dieses Ansatzes für parallele Hybridfahrzeuge finden sich in der Literatur [31, 79, 157, 173, 108, 14].

²⁷ engl. State of Charge

Um harte Übergänge zwischen unterschiedlichen Kennfeldbereichen zu vermeiden, kann der Ansatz durch Fuzzy-Logik erweitert werden [106, 151, 107].

Beim kennfeldbasierten Ansatz müssen ausreichend Eingangsgrößen zur Bedienung der Kennfelder vorhanden sein, was diesem Ansatz für robuste Anwendungen einen hohen Applikationsaufwand auferlegt.

Regelbasierte Strategie

Regelbasierte Energiemanagementstrategien lassen sich in endlichen Zustandsautomaten abbilden (siehe Abb. 3.2).

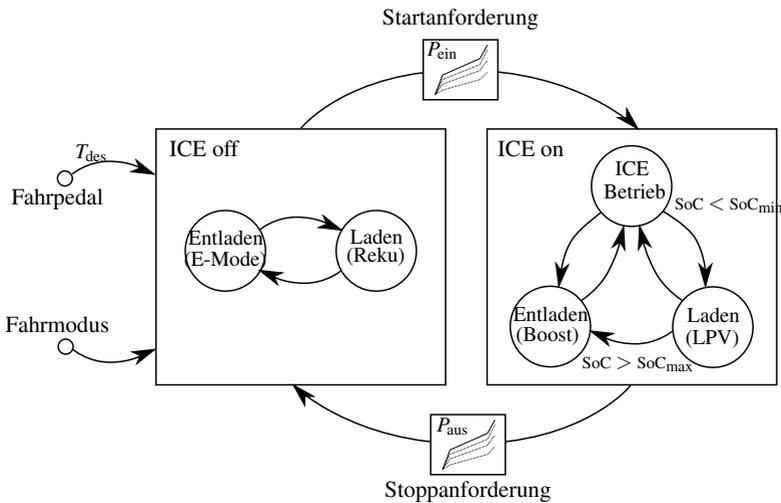


Abb. 3.2.: Regelbasierte, heuristische Energiemanagementstrategie in Form eines endlichen Zustandsautomaten nach [68, 176]

Der Fahrer beeinflusst die Strategie durch ein Fahrerwunschmoment T_{des} am Gaspedal und durch Wahl eines gewünschten Fahrmodus. Der Fahrmodus legt eine der drei übergeordneten Ziele der Strategie fest:

- Entladen (Charge Depleting CD)
- Ladungserhaltung (Charge Sustaining CS)
- Laden (Charge Increasing CI)

Ein Fahrmodus beinhaltet mehrere Regeln, die über Zustandsübergänge entscheiden. Einzelne Betriebsmodi entscheiden über den aktuellen Zustand.

Rein elektrisches Fahren (E-Mode) und Rekuperation (Reku) werden ausgewählt, wenn der Verbrennungsmotor nicht läuft (ICE off). Eine Start- oder Stoppanforderung wird getroffen, wenn eine bestimmte Ein- und Ausschaltleistung P_{ein} und P_{aus} vorliegt. Diese kann vom aktuellen SoC abhängen und in Form von Hysteresekeinfeldern abgelegt sein. Wird bei angekoppelter Verbrennungsmaschine (ICE on) eine untere Ladezustandsgrenze der Batterie SoC_{min} unterschritten, wird durch Lastpunktverschiebung (LPV) nachgeladen. Bei Überschreiten einer maximalen Ladezustandsgrenze SoC_{max} kann der Verbrennungsmotor unterstützt (Boost) werden oder über eine Stoppanforderung die Batterie im E-Mode entladen werden.

Regel- und kennfeldbasierte Ladestrategie

In [54] wird bei angekuppeltem Verbrennungsmotor eine Ladestrategie verfolgt, die festlegt, welcher Betriebsmodus in, welcher Situation geeignet ist. Das Umschalten der Betriebsmodi erfolgt über Einschränkungen des verfügbaren Energieinhalts der Batterie (siehe Abb. 3.3). Vom prozentualen Energieinhalt der Batterie SoC_{abs} ist zum Schutz der Batterie nur ein Bereich zwischen $\text{SoC}_{\text{min}} < \text{SoC}_{\text{rel}} < \text{SoC}_{\text{max}}$ verfügbar, indem sich der relative SoC_{rel} befindet. Aus diesem erfolgt je nach Applikation der Fahrmodi eine weitere Einschränkung in einem strategischen SoC_{stgy} -Fenster, in dem sich idealerweise ein Soll- SoC_{soll} befindet. Ziel der Ladestrategie ist es, diesen SoC_{soll} bedarfsgerecht zu steuern. Dazu werden im strategischen SoC_{stgy} -Fenster Bereiche um den SoC_{soll} aufgespannt, in denen in unterschiedlichen Stufen Betriebsmodi zum Laden und Entladen ausgewählt werden. Hinter diesen Stufen befinden sich Kennfelder, die bedarfsgerecht und wirkungsgradoptimal ausgelegt sind.

Wie in [54] beschrieben, unterscheiden sich die Lade- und Entladestufen durch die Gewichtung des bedarfsorientierten oder wirkungsgradoptimalen Ladens bzw. Entladens. Laden 3 bzw. Entladen 3 haben ein schnelles Zurückführen des aktuellen SoCs in Richtung SoC_{soll} zur Folge. Die Stufe Bordnetz bedeutet, dass nur so viel elektrische Energie geladen wird, um die aktuelle Bordnetzleistung zu decken. Bei Nullladen wird keine elektrische Energie erzeugt, sodass der Leistungsbedarf des Bordnetzes aus der Batterie abgedeckt wird. Bei höheren Geschwindigkeiten v wird der Bereich für die Bordnetzerhaltung ausgedehnt, um Segeln zu unterstützen.

Entladestrategien im PHEV

Bei einem PHEV mit einer elektrischen Reichweite (AER) von mehreren zehn Kilometern ist eine übergeordnete Planung der Entladung der Batterie möglich. Wählt der Fahrer keinen Fahrmodus explizit aus, können zwei Arten von Strategien verfolgt werden: Bei voller Batterie ist die einfachste Entladestrategie die Charge Depleting Charge Sustaining Strategie (CDCS).

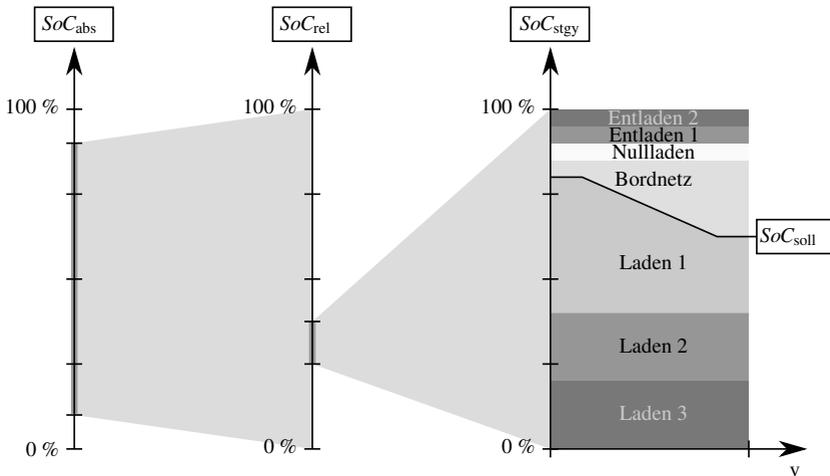


Abb. 3.3.: Bedarfsgerechte und wirkungsgradoptimale Ladestrategie mit Regeln und Kennfeldern nach [54, 176]

In Abb. 3.4 ist eine typische Trajektorie für eine CDCS Strategie dargestellt. Dabei wird in der Anfangsphase (Charge Depleting) hauptsächlich elektrisch gefahren und damit kein oder wenig Kraftstoff verbraucht.

Beim Erreichen der elektrischen Reichweite, die durch das Unterschreiten eines bestimmten SoCs vorgeben wird, beginnt die Ladungserhaltungphase (CS). Dabei wird ein SoC_{soll} z. B. durch eine regelbasierte Ladestrategie gehalten, die sich im CS-Bereich aufhält. Diese Strategie stellt ein für den Fahrer nachvollziehbares und reproduzierbares Verhalten auf verschiedenen Strecken dar.

Ist die Route bekannt, kann das Wissen über die Fahrzeit und die Distanz verwendet werden, um eine sogenannte Blending Strategie anzuwenden, bei der eine kontinuierliche Entladung der Batterie stattfindet. Die Blending Strategie stellt eine optimale Strategie [104, 63] dar, deren Berechnung im Folgenden genauer betrachtet wird.

3.2.2. Optimale Energiemanagementstrategien

Bei der Optimierung des Energiemanagements werden zwei Kategorien unterschieden: Methoden, die zur global optimalen Lösungen führen und meist nur für Referenzbetrachtungen offline berechnet werden und Optimierungsmethoden, die in Form von Reglern online im Fahrzeug eingesetzt werden. Während für die Kategorie der offline Optimierung numerische Methoden maßgeblich verwendet werden, gibt es für die online Optimierung eine Vielzahl von Regleransätzen, die von Ergebnissen nahe der globalen Lösung bis hin zu lokal optimalen Lösungen führen [156].

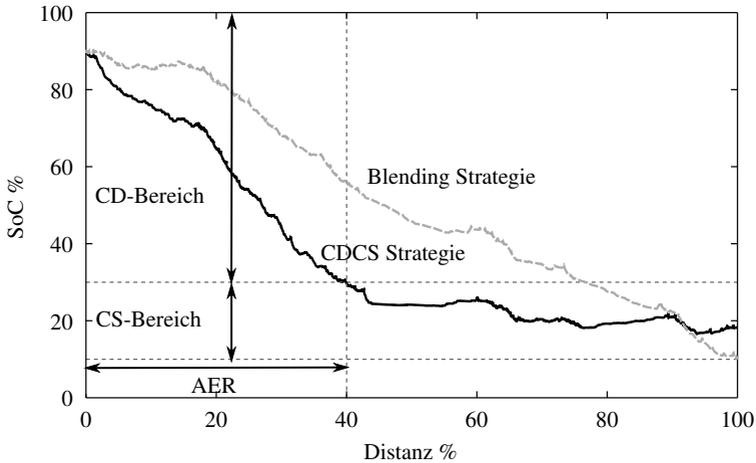


Abb. 3.4.: Typische Trajektorien für die Charge Depleting Charge Sustaining Strategie (CDCS) und die Blending Strategie in Anlehnung an [104]

Offline Optimierung

Die offline Optimierung wird auch als nicht-kausale Optimierung bezeichnet, da die Streckeninformationen zu Beginn der Optimierung vorliegen müssen. Es wird zwischen numerischen und analytischen Ansätzen unterschieden.

Formulierung des Optimierungsproblems: Als Gütemaß und damit die zu minimierende Größe J wird das Integral des Kraftstoffverbrauchs bis zum betrachteten Zeitpunkt $t = T$ verwendet. Das deterministische Optimierungsproblem lässt sich damit wie folgt beschreiben:

$$\min_{u(t)} J = \int_0^T \dot{m}_f(u(t), z(t)) dt \quad (3.1)$$

Der Fahrzyklus, der aus Geschwindigkeits- und Streckeninformationen besteht, wird als Störgröße $z(t)$ des dynamischen Systems $f(\text{SoC}(t), u(t), z(t), t)$ betrachtet, welches als weitere Eingangsgrößen den Batterieladezustand $\text{SoC}(t)$ und die Steuergrößen $u(t)$ beinhaltet.

Weitere Randbedingungen des Optimierungsproblems in Gl. 3.1 sind:

$$\dot{\text{SoC}} = f(\text{SoC}(t), u(t), z(t), t), \quad (3.2)$$

$$\text{SoC}(t = 0) = \text{SoC}_0, \quad (3.3)$$

$$\text{SoC}(t = T) = \text{SoC}_T, \quad (3.4)$$

$$\text{SoC}_{\min} \leq \text{SoC}(t) \leq \text{SoC}_{\max}. \quad (3.5)$$

Numerische Optimierung: Bei der klassischen, numerischen Optimierung wird die Dynamische Programmierung (DP)[20] angewendet, die in Kap. 5 detailliert beschrieben wird. Durch die numerische Vorgehensweise werden Zustands- und Steuergrößen und die Zeit diskretisiert sowie das dynamische System durch Differenzgleichungen dargestellt. Das Ergebnis der DP ist garantiert optimal, vernachlässigt man die numerischen Fehler, die durch Diskretisierung und Interpolation entstehen.

Bei der DP wird das Gütemaß (Gl.3.6) um eine Schrittkostenfunktion $J(\text{SoC}, t)$ erweitert, die zu jedem Zeitpunkt t_k den aufsummierten minimalen Verbrauch für jeden Zustand SoC_i widerspiegelt²⁸. Alle Steuergrößen u die im möglichen Stellbereich U liegen werden bei der Minimierung nur betrachtet.

$$J(\text{SoC}_i, t_k) = \min_{u \in U} \{ \dot{m}_f(\text{SoC}_k, u_k, z_k) \cdot \Delta t + J((\text{SoC}_i + f(\text{SoC}_k, u_k, z_k, t_k)) \cdot \Delta t) \} \quad (3.6)$$

Vom letzten Zeitschritt t_T ausgehend wird in zeitdiskreten Schritten Δt die Schrittkostenfunktion berechnet und die dazugehörigen Steuergrößen gespeichert. Bei $t = 0$ wird die optimale Strategie $u^*(t)$ für einen gewählten Ausgangszustand durch Pfadrückverfolgung der optimalen Zustände $\text{SoC}^*(t)$ aus der Kostenfunktion bestimmt [22].

$$u^*(t_k) = \arg \{ J(\text{SoC}^*, t_k) \} \quad (3.7)$$

$$\text{SoC}^*(t_{k+1}) = \text{SoC}^*(t_k) + f(\text{SoC}^*(t_k), u^*(t_k), z(t_k), t_k) \cdot \Delta t$$

Analytische Optimierung mit Indirekten Verfahren: Auf Basis einer analytischen Lösung wird das Maximumsprinzip von PONTRJAGIN [134, 56] verwendet. Dabei wird die HAMILTON Funktion H zu jedem Zeitschritt nach $u(t)$ minimiert. Die optimale Steuerstrategie ergibt sich somit aus:

$$u^*(t) = \arg \min_{u(t)} \{ H(\text{SoC}(t), u(t), \lambda(t), t) \}, \quad (3.8)$$

wobei

$$H(\text{SoC}(t), u(t), \lambda(t), t) = \dot{m}_f(z(t), u(t)) + \lambda(t) \cdot f(\text{SoC}(t), u(t), z(t), t). \quad (3.9)$$

²⁸ Der Index i repräsentiert einen Zustand im diskreten Zustandsraum

Die zu lösende, adjungierte Differenzialgleichung lautet:

$$\frac{d\lambda(t)}{dt} = -\frac{\partial H}{\partial \text{SoC}} = -\frac{\partial}{\partial \text{SoC}} f(\text{SoC}(t), u(t), z(t), t) \quad (3.10)$$

Zur Lösung der HAMILTON Gleichung müssen $\dot{m}_f(u(t), z(t))$ und $f(\text{SoC}(t), u(t), z(t))$ als explizite Funktionen dargestellt oder als solche approximiert werden.

Nach [68] wird bei der äquivalenten Verbrauchsminimierungsstrategie²⁹ (ECMS) folgende Vereinfachung zur Lösung des Optimierungsproblems getroffen:

Die Abhängigkeit des Batteriezustands $\text{SoC}(t)$ in Gl. (3.2) wird vernachlässigt. Dies ist für eine Li-Ionen Batterie im Arbeitsbereich und der Modellierung der Batterie durch einen internen Widerstand möglich [156]. Gl. (3.10) ist mit $\text{SoC} \approx f(u(t), z(t))$ als konstant anzunehmen:

$$\frac{d\lambda(t)}{dt} = 0. \quad (3.11)$$

Der Äquivalenzfaktor λ beschreibt die optimale Gewichtung zwischen der Änderungsrate des Ladezustands und des Kraftstoffmassenstroms für einen Zyklus. Durch die Annahme einer konstanten Spannung im Ersatzschaltbild des Batteriemodells kann Gl. (3.9) als Leistungsaufteilung ausgedrückt werden [68]:

$$P_H(u(t), s, t) = P_f(u(t), z(t)) + s_0 \cdot P_{\text{ech}}(u(t), z(t)). \quad (3.12)$$

Mit der verbrennungsmotorischen Leistung $P_f = \dot{m}_f(u(t), z(t)) \cdot H_u$ und der elektrochemischen Leistung $P_{\text{ech}} = \text{SoC}(u(t), z(t)) \cdot U_{\text{oc}} \cdot Q_0$ wird s_0 zum dimensionslosen Skalierungsfaktor:

$$s_0 = -\lambda \frac{H_u}{U_{\text{oc}} \cdot Q_0} \quad (3.13)$$

s_0 verdeutlicht, dass das Entnehmen elektrischer Leistung einen erhöhten Kraftstoffverbrauch beim Wiederaufladen zur Folge hat, soweit keine Energie durch Rekuperation gewonnen wurde (vgl. Abschnitt 2.2.3).

Optimale Online-Regelstrategien

Der Äquivalenzfaktor λ variiert je nach Fahrzyklus [155, 128]. Ohne Kenntnis über die vorausliegende Strecke muss $\lambda(t)$ bei einer online Regelstrategie ständig angepasst werden. Dabei finden sich in der Literatur eine Vielzahl von Ansätzen, wie $\lambda(t)$ an die aktuellen Umgebungsbedingungen angepasst werden kann.

In [155] und [18] werden verschiedene optimale Regelkonzepte mit der ECMS-Methode vorgestellt und miteinander verglichen. Dabei wird der Äquivalenzfaktor auf Basis mittlerer Effizienzen bestimmt [131, 130, 133], der Ladezustand des Äquivalenzfaktors durch einen empirisch gewählten Korrekturfaktor [109] oder einen PI-Regler [39] ermittelt sowie der Äquivalenzfaktor durch vergangene [85, 67] und aktuelle Fahrverläufe angepasst [163, 164, 84, 35].

²⁹ engl. Equivalent Consumption Minimization Strategy

3.2.3. Prädiktive Energiemanagementsysteme

Strategien, die nur vergangene und aktuelle Informationen verarbeiten, versagen, wenn die Menge an rekuperierter Energie groß im Vergleich zur Speicherkapazität der Batterie ist [10]. Aus diesem Grund fließen bei prädiktiven Energiemanagement Systemen zukünftige Informationen in die Berechnung mit ein. Es sind verschiedene Ansätze zu nennen [18].

Prädiktive regelbasierte Strategien

Bei regelbasierten Strategien werden zukünftige Streckeninformationen meist durch eine Erweiterung der Basisstrategie verwendet, indem die Grenzen zwischen den verschiedenen Betriebsmodi in Abhängigkeit der Fahrstreckenprognose variiert werden [18]. Dabei werden zukünftige Situationen, wie Boost- oder Rekuperationsphasen prognostiziert. In [139] wird der künftige SoC-Verlauf mithilfe eines künstlichen neuronalen Netzes abgeschätzt. In [36] und [97] liegt der Fokus auf den Start- und Stoppvorgängen des Verbrennungsmotors, die durch eine Prognose der Rekuperationsphasen und einer Leistungsprädiktion erheblich reduziert werden können. WILDE [172] passt die regelbasierte Strategie an verschiedene Fahrsituationen an und spart durch eine höhenprofilabhängige SoC-Regelung zwischen 1,5 % und 2,7 % Kraftstoff ein.

Prädiktive ECMS Strategien

Der ECMS Ansatz wird in [154] zu einer Telemetry-based ECMS (T-ECMS) erweitert. Dabei wird aus Telemetriedaten der vorausliegenden Strecke ein Geschwindigkeitsprofil erzeugt, das aus Beschleunigungs-, Verzögerungs- und Konstantphasen besteht, die so ausgelegt sind, dass die restliche Strecke mit der kürzesten Zeit durchfahren wird. Aus dem Geschwindigkeitsprofil wird eine Radleistung berechnet, die in die Berechnung von $\lambda(t)$ einfließt, indem das Verhältnis der rekuperierbaren Energie zur mechanischen Energie ermittelt wird.

BECK [18] verfolgt einen ähnlichen Ansatz unter dem Begriff Predictive ECMS (P-ECMS) und berücksichtigt zusätzlich das Motorstartverhalten sowie die Gangwahl.

Eine weitere Variante wird von STIEGELER [162] vorgestellt, bei der der Ladezustand von λ durch einen P-Regler fortwährend korrigiert wird. Die Prädiktion erfolgt durch eine vorherige Berechnung der optimalen SoC-Strategie für die relevante Strecke. Diese dient der Onlineregulierung als Zielgröße.

KUTTER [99] bestimmt λ mit einer Variante der ECMS-Methode, indem das PONTYAGINSche Maximumsprinzip über den Zeithorizont iterativ gelöst wird. Dabei werden mehrere numerische Nullstellensuchverfahren miteinander verglichen, um eine schnelle Berechnung einer optimalen Strategie zu gewährleisten.

Prädiktive Strategien mit der DP

Die Dynamische Programmierung wird in einigen Ansätzen verwendet, um die optimale Strategie bis zum Fahrtziel zu berechnen. Dabei wird die aufwendige Berechnung der Optimierung durch unterschiedliche Verfahren reduziert. Die viel zitierte Arbeit von BACK [12] verwendet die DP als Optimierung in einer nichtlinearen, modellprädiktiven Antriebsstrangregelung für ein MHEV. Echtzeitfähigkeit wird durch die Berechnung eines kurzen Regelhorizonts erreicht, der zyklisch erneuert wird. Weiter wird der Zustandsraum stark eingeschränkt und die Diskretisierung variabel gehalten, um innerhalb einer kurzen Abtastzeit zu liegen. Die prädiizierte Geschwindigkeit wird wie bei [154] anhand von Telemetriedaten sowie einer Fahrerklassifizierung berechnet. Eine Kraftstoffeinsparung von 2 % zur nichtprädiktiven Basisstrategie wird dadurch im Realbetrieb erreicht.

Andere vergleichbare Arbeiten wurden nur in der Simulation durchgeführt und verweisen auf die starken Einschränkungen bei einer echtzeitfähigen Applikation im Fahrzeug [63, 25].

Für Fahrzeuge im öffentlichen Nahverkehr sind die Routen fest vorgegeben. JOHANNESSON [87] untersucht Geschwindigkeitsprofile für bekannte Routen und entwirft einen Regler mithilfe eines stochastischen Geschwindigkeitsmodells und der Stochastischen Dynamischen Programmierung. Dieser Modellprädiktive Regler hat als Vorgabe die Schrittkostenfunktion (vgl. Gl. (3.6)), die für ein historisches Geschwindigkeitsprofil vorab bestimmt wurde. Im Fahrzeug weicht die Geschwindigkeit durch Verkehr vom historischen Profil ab. Die berechneten Schrittkosten beinhalten die globale Information und ermöglichen so eine optimale Regelung trotz verschiedenem Profil. Es wurde bei diesem Ansatz gezeigt, dass trotz abweichenden Geschwindigkeiten dieses Verfahren Ergebnisse nahe des globalen Verbrauchsoptimums für einen HEV erzielt und somit das Höhenprofil der Route einen dominanten Einfluss auf die Strategie hat [88]. Als Weiterentwicklung wird das Fahrzeugmodell stark vereinfacht sowie die Berechnung der Kostenfunktion durch Anwenden der Approximierten Dynamischen Programmierung beschleunigt [86].

Die Übertragbarkeit des Ansatzes auf Plug-in Hybridfahrzeuge ist nicht gewährleistet und wird von LARSSON [103] weiter untersucht. Aufgrund der größeren Energiedichte der Batterie in einem PHEV wird die Kostenfunktion durch kubische Splines approximiert. Dadurch verkleinert sich die Speichergröße der Kostenfunktion. Diese lässt sich so nach einer offline Berechnung per Funkverbindung auf das Fahrzeug übertragen [103]. Die optimale Regelung erfolgt nach dem modellprädiktiven Regelprinzip von JOHANNESSON.

3.3. Kombination eines prädiktiven Energiemanagements mit einer prädiktiven Fahrstrategie

Da die Wahl der Geschwindigkeit große Auswirkungen auf das meist nachgelagerte Energiemanagement hat, ermöglicht ein Verknüpfen der beiden Strategien weitere Verbrauchseinsparungen. Als Resultat entsteht ein Fahrerassistenzsystem, das dem Fahrer die Längsführung abnimmt und dadurch die erheblichen Unsicherheiten bei der Prädiktion eines Geschwindigkeitsverlaufs reduziert, während diese Informationen direkt in einem prädiktiven Energiemanagement umgesetzt werden können.

Die bisher umgesetzten Varianten basieren alle auf einer getrennten Anordnung beider Systeme sowie einer überlagerten Koordination. Es sind sowohl regelbasierte [129, 50], wie auch optimierungsbasierte [91, 89] Ansätze zu finden. Der Fokus aller Arbeiten liegt allein auf der geeigneten Verzögerung des Fahrzeugs, um durch Rekupe-
rationsphasen möglichst viel kinetische Energie in elektrische Energie umzuwandeln [89]. Verbrauchseinsparungen betragen zwischen 4 % [50] und 9 % [129, 91].

3.4. Fahrzyklen zur Bewertung von Betriebsstrategien

Die Bewertung geeigneter Strategien ist stark von der Wahl des gefahrenen Fahrprofils abhängig. Diese sind entscheidend bei der Typisierung neuer Fahrzeuge zur Ermittlung der Emissions- und Verbrauchswerte.

Nach FLECKNER [54] lassen sich zwei Kategorien unterscheiden. Die genormten Fahrzyklen garantieren die Reproduzierbarkeit bei einer Typisierung, während durch Realfahrzyklen die Robustheit in einem repräsentativen Realfahrverhalten nachgewiesen werden kann.

3.4.1. Genormte Fahrzyklen

Genormte Fahrzyklen dienen der Vergleichbarkeit verschiedener Fahrzeuge. Dabei sind gesetzliche Fahrzyklen als Untergruppe zu nennen, die in einem Land oder Region zur Typisierung auf einem Rollenprüfstand verwendet werden. Die wichtigsten aktuellen Fahrzyklen für Personenkraftwagen sind der *Neue Europäische Fahrzyklus* (NEFZ) für Europa, die *Federal Test Procedure* (FTP75) für die USA und der *Japanese Cycle* (JC08) für Japan [2].

Aufgrund zunehmender Kritik an der Diskrepanz zwischen realen und typisierten Verbrauchswerten entwickelt das World Forum for Harmonization of Vehicle Regulations (WP.29) unter der Schirmherrschaft der United Nations Economic Commission for Europe (UNECE) ein weltweit harmonisiertes Typisierungsverfahren, den *World-wide harmonized Light Vehicle Test Cycle* (WLTC), der spätestens ab 2020 den NEFZ ersetzen soll.

NEFZ

Das Fahrprofil des NEFZ wurde im Jahr 1996 eingeführt und setzt sich aus vier Stadt-fahrzyklen und einem außerstädtischen Fahrzyklus zusammen [174]. Die Gesamtdauer beträgt 1180 Sekunden bei einer gefahrenen Strecke von ca. 11 Kilometern, wobei Abweichungen bei der Geschwindigkeit (± 2 km/h) und der Zeit (± 1 s) toleriert werden. Die Typisierung eines Plug-in Hybridfahrzeugs erfolgt nach [174] in zwei Prüfungen:

- Kraftstoffverbrauch C_1 im Charge Depleting Modus (volle Batterie) zur Bestimmung der AER
- Kraftstoffverbrauch C_2 im Charge Sustaining Modus (Mindestladung)

In der ersten Prüfung wird der Zyklus bei einer vollgeladenen Batterie bis zum ersten Verbrennungsmotorstart elektrisch gefahren. Die zurückgelegte Strecke wird als AER gewertet. In der zweiten Prüfung wird mit voller Batterie gestartet und bis zu einer geforderten Mindestladung konstant gefahren. Ist diese erreicht, beginnt die Ermittlung des Kraftstoffverbrauchs C_2 , die nach Abschluss der letzten Leerlaufphase des außerstädtischen Fahrzyklus endet. Mit der angenommenen Strecke von $D_{av} = 25$ km berechnet sich der kombinierte Kraftstoffverbrauch C zu:

$$C = \frac{\text{AER} \cdot C_1 + D_{av} \cdot C_2}{\text{AER} + D_{av}} \quad (3.14)$$

Das Versuchsfahrzeug (PHEV) hat bei einer AER = 36 km einen kombinierten Verbrauch von 3,1 l/100km [158].

WLTC

Für den WLTC wurden Geschwindigkeitsprofile aus der EU, Schweiz, Indien, Japan, Korea und den USA gesammelt. Diese Referenzdatenbank umfasst über 765.000 km gesammelte Daten in unterschiedlichen Fahrzeugklassen, Straßenklassen (Stadt, Überland, Autobahn) und Fahrbedingungen (Maximal- und Minimalauslastung, Wochenende). Aus dieser Datenbank werden Einzelprofile für den Fahrzyklus generiert. Die Auswahl der Fahrprofile erfolgt nach Leistungsgewicht und maximaler Fahrzeuggeschwindigkeit [167].

Bei der Typisierung werden sowohl CD, als auch CS Phasen betrachtet, wobei Haltezeiten, Laden und ein Vorkonditionieren genau vorgegeben werden [33]. In die Berechnung des kombinierten Verbrauchs FC werden die Verbräuche der CD Phasen ($FC_{CD,j}$) und der CS-Phase (FC_{CS}) mit sogenannten *Utility Faktoren* (UF_j) verrechnet, die den alltäglichen Gebrauch eines bestimmten Hybridmodus durchschnittlich abbilden sollen.

Diese nehmen mit der elektrischen Reichweite ab und sind somit von den einzelnen Phasen und dem gesamten Zyklus abhängig. Der kombinierte und gewichtete Kraftstoffverbrauch errechnet sich somit zu [33]:

$$FC_{\text{weighted}} = \sum_{j=1}^k (UF_j \cdot FC_{CD,j}) + \left(1 - \sum_{j=1}^k UF_j\right) \cdot FC_{CS} \quad (3.15)$$

Der WLTC ist im Vergleich zum synthetischen NEFZ Fahrzyklus deutlich dynamischer und deckt durch eine höhere Leistungsanforderung mehr Betriebszustände ab.

Real Drive Emissions

Die Europäische Kommission plant die Grenzwerte der Emission bei der Typisierung getrennt zu bestimmen [136]. Dabei stehen zwei Testverfahren der Real Drive Emissions (RDE) zur Auswahl:

PEMS: Das Portable Emission Measurement System (PEMS) ist ein aufwendiges Messinstrument, das die Emission im realen Straßenverkehr aufzeichnet. Die Vorkonditionierung der Fahrzeuge und die Reproduzierbarkeit sind damit ausgeschlossen.

RCG: Der Random Cycle Generator (RCG) greift auf die Datenbank des WLTC zurück und erstellt daraus für die jeweilige Klasse zufällige Fahrzyklen, die auf dem Rollenprüfstand abgefahren werden können. Eine Reproduzierbarkeit der Randbedingungen ist damit möglich [136, 66].

Genormte Fahrzyklen dienen primär der Typisierung für unterschiedliche Fahrzeuge. Für Hybridfahrzeuge und Plug-in Hybridfahrzeuge sind daher nachträgliche Korrekturen vorgesehen, die ein gezieltes Auslegen der Betriebsstrategie an den gesetzlichen Zyklus fördern und theoretische Verbrauchsangaben hervorbringen. Bei genormten Zyklen fehlen in der Regel Höheninformationen, die bei einer optimalen Betriebsstrategie entscheidend einfließen. Für die Auslegung einer optimalen prädiktiven Betriebsstrategie sind genormte Fahrzyklen somit nicht geeignet.

3.4.2. Realfahrzyklen

Bei der Generierung von Realfahrzyklen aus Messdaten kann nach [15] auf drei Methoden zurückgegriffen werden: Verfolgungsfahrt, Mitschwimmen und Musterfahrt. Während bei der Verfolgungsfahrt und dem Mitschwimmen im Verkehr ein oder mehrere zufällige Fahrzeuge den Fahrstil bestimmen, kann bei der Musterfahrt ein gewünschtes Fahrverhalten vorgegeben werden.

Neben zeitaufwendigen Messaufzeichnungen besteht die Möglichkeit, Realzyklen aus statischen Geschwindigkeitsinformationen einer digitalen Karte sowie aus dynamischen Verkehrsflussdaten zu generieren.

Datenbanken mit Verkehrsflussdaten bieten zeit- und positionsabhängige Geschwindigkeitsverteilungen, die ein Mitschwimmen sehr gut abbilden und aufwendige Versuchsfahrten ersetzen.

Stuttgart-Runde

Die Stuttgart-Runde ist durch eine Kombination der Methoden Mitschwimmen und Musterfahrt entstanden [54]. Dabei wurden unterschiedliche Fahrstile vorgegeben. Der in dieser Arbeit betrachtete vorausschauende Fahrstil beinhaltet die Anweisung, unnötiges Beschleunigen und Verzögern zu vermeiden [54]. Die 64,5 km lange Strecke in und um Stuttgart setzt sich aus Stadt-, Überland-, Schnellstraßen und Autobahnanteilen zusammen (siehe Tab. 3.1).

Tab. 3.1.: Prozentuale Streckenverteilung der Stuttgart-Runde

	Autobahn	Schnellstraße	Überland	Stadt
Anteil	24,7 %	18,7 %	26,1 %	30,5 %

Die im Versuchsfahrzeug vorhandene, heuristische Basisstrategie wurde auf die Stuttgart-Runde abgestimmt. Der Kraftstoffverbrauch beträgt in der Simulation 4,4 l/100km [100].

Deutschland-Runde

Die Deutschland-Runde ist ein ca. 82 km langer Rundkurs um das Porsche Entwicklungszentrum in Weissach mit einer repräsentativen Abdeckung der Straßenklassenanteile von Deutschland (siehe Tab. 3.2). Sie wurde aus statischen Kartendaten erstellt und beinhaltet ein Höhenprofil sowie gesetzliche Geschwindigkeitsbegrenzungen. Ein fahrbares Geschwindigkeitsprofil wird in Kap. 5 bei der Vorstellung optimaler Geschwindigkeitsstrategien berechnet.

Tab. 3.2.: Prozentuale Verteilung des klassifizierten, deutschen Straßennetzes (Stand 01.01.2013) [161] und der Deutschland-Runde

	Dt. Straßennetz	Deutschland-Runde
Autobahn	5,59 %	6,00 %
Bundesstraßen	17,18 %	17,35 %
Landesstraßen	37,40 %	38,47 %
Kreisstraßen	39,83 %	39,12 %
innerorts	22,07 %	25,60 %
außerorts	77,93 %	74,40 %

Autobahn-Runde

Die Autobahn-Runde startet am Porsche Entwicklungszentrum in Weissach und verläuft größtenteils auf der A8 Richtung München. Mit einer Länge von 129 km sind zwei Autobahnkreuze abgedeckt, die bei Hin- und Rückfahrt durchfahren werden. Weitere Angaben zum Zyklus sowie das Höhenprofil sind in Anhang A.3 zu finden.

Langstrecken

Zur Untersuchung des Verkehrseinflusses auf Langstrecken werden verschiedene Routen bei den Untersuchungen in Kap. 7 verwendet. Da Strecken über mehrere hundert Kilometer vorwiegend auf Autobahnen zurückgelegt werden, dominiert diese Straßenklasse bei den ausgewählten Langstrecken. Eine detaillierte Beschreibung der einzelnen Langstrecken ist Tab. 3.3 und im Anhang A.3 zu finden.

Tab. 3.3.: Betrachtete Langstrecken

Start-Ziel	Straßennamen	Streckenlänge	Höhenmeter
Ulm-Bozen	A7 B179 B189 A12 SS12	342 km	1290 m
Bozen-Ulm	SS12 A12 B189 B179 A7	342 km	1290 m
Karlsruhe-München	A8	287 km	673 m
Salzburg-Ulm	A8 A99 A8	304 km	308 m
Basel-Frankfurt	A5	326 km	166 m

3.5. Prädiktive Streckendaten

Prädiktive Streckendaten sind bei einer vorausschauenden Strategieoptimierung notwendig. Neben der Festlegung einer Route ist die Qualität der Streckeninformationen und ihre Aktualität von großer Bedeutung.

3.5.1. Energetisch optimale Routenplanung

Entscheidend für den Kraftstoffverbrauch ist die Wahl der Route. Bei fehlender Ortskenntnis oder längerer Reisedistanz wird die Routenwahl von Navigationssystemen getroffen. Diese bieten meist zeit- oder distanzoptimale Routenführung an. Auch wenn sich die Zeit bei einer energetischen Betrachtung entscheidend auf das Ergebnis auswirkt, führen zeit- oder distanzoptimale Routen nicht unbedingt zur Reduzierung des Kraftstoffverbrauchs [16]. Schnelle Routen führen auf Straßen mit höherer Durchschnittsgeschwindigkeit, wobei eine längere Umfahrung in Kauf genommen wird. Höhere Geschwindigkeiten resultieren in höherem Kraftstoffverbrauch und mehr Emissionen.

Beim Eco-Routing wird eine energieeffiziente Route für ein Fahrzeug vom Start bis zum Reiseziel identifiziert. Dabei werden bei einer Untersuchung im realen Verkehr 17-25 % Kraftstoff durch eine geeignete energetisch optimalen Routenwahl eingespart [9]. In [17] kann der mittlere Kraftstoffverbrauch einer energieeffizienten Route an Stelle der schnellsten Route um über 10 % reduziert werden.

Zur Berechnung dieser Eco-Routen sind nach [120] drei Kartenattribute entscheidend für die Routenwahl: Geschwindigkeitsinformationen, Steigung bzw. Höhenverläufe sowie die Information über Anhaltevorgänge.

Geschwindigkeitsübergänge sowie Anhaltevorgänge beinhalten Beschleunigungs- und Verzögerungsphasen, die maßgebend den Energieverbrauch beeinflussen. Der Höhenverlauf einer Route wirkt sich je nach Antriebsstrangtopologie unterschiedlich auf den Verbrauch aus. Bei konventionell angetriebenen Fahrzeugen ergibt sich in verschiedenen Studien ein Mehrverbrauch bei zunehmender Steigung [32, 132, 52].

Hybridfahrzeuge dagegen können bei Routen mit Gefällen durch Rekuperation Energie nachladen und je nach Fahrzeugauslegung Kraftstoff einsparen [90]. Eine antriebsstrangabhängige Routenplanung ist neben Hybridfahrzeugen besonders für Elektrofahrzeuge wichtig, da die Reichweite, die stark von der Route abhängt, begrenzt ist und verfügbare Ladestationen in die Planung mit einbezogen werden müssen [94].

Geschwindigkeitsinformationen sind meist gesetzliche Geschwindigkeitsbegrenzungen, die in statischen Karten hinterlegt sind. Dynamische Geschwindigkeiten bilden aktuelle Verkehrssituationen besser ab und ermöglichen dadurch eine genauere Zeit- und Verbrauchsprognose.

Navigationssysteme sowie prädiktive Energiemanagementsysteme greifen auf unterschiedliche Informationen in statischen und dynamischen digitalen Karten zurück, die im Folgenden vorgestellt werden.

3.5.2. Statische Kartendaten

NAVTEQ/HERE (NOKIA) und TELE ATLAS (TOMTOM) sind die führenden Kartenanbieter, die Daten für statische Kartenattribute stetig sammeln und über standardisierte Datenformate und Produkte im Markt anbieten [48]. Eine Aktualisierung statischer Kartendaten ist für praktische Anwendungen in der Navigation und in Advanced Driver Assistance Systems (ADAS) notwendig. Zur Beschleunigung dieses Vorgangs treibt eine Initiative aus mehreren Kartenherstellern und Automobilzulieferern und -herstellern seit 2009 die Entwicklung eines Navigation Data Standards (NDS) voran [123].

Für die speziellen Anforderungen an ADAS Systeme werden Schnittstellen entworfen, die eine schnelle Kommunikation der Navigation mit den Steuergeräten ermöglicht. Das ADASIS-v2 Protokoll [141] beinhaltet eine Schnittstellenspezifikation für die Anbindung unterschiedlicher Komponenten im Fahrzeug an das Navigationssystem. Über den CAN-Bus werden Daten für einen elektronischen Horizont³⁰ (EH) versendet, der

³⁰ engl. Electronic Horizon (eHorizon)

sich in Fahrtrichtung vor dem Fahrzeug in Baumstruktur aufbaut. Dieser wird zyklisch erneuert und beinhaltet unter anderem folgende Attribute: Straßenklasse, Verkehrsschilder, Geschwindigkeitsbeschränkungen, Richtungsänderungen, Kurvenkrümmungen, Steigungen und Kreuzungsinformationen. Ohne Zielführung orientiert sich der Aufbau der relevanten Segmente am wahrscheinlichsten Pfad³¹ (MPP).

Die Architektur eines EH Systems beinhaltet zwei Module, die über einen Datenkanal (z. B. den CAN) verbunden sind [110]:

eHorizon Provider (EHP) und eHorizon Reconstructor (EHR). Der EHP ist im Fahrzeug mit der Navigation und Lokalisierung gekoppelt und sendet Datenpakete über den CAN. Jedes Steuergerät, das ADAS Funktionen enthält, ist mit dem EHR Modul ausgerüstet, das die komprimierten Daten, die über den CAN ankommen, empfängt und entschlüsselt.

Für viele ADAS Funktionen reicht ein EH von wenigen Kilometern aus, während für die prädiktive Strategieplanung aus energetischer Sicht die einzelnen Attribute entlang der gesamten Route schon zu Beginn der Fahrt möglichst schnell vorliegen müssen. Dies ist durch eine separate Botschaft, die Informationen bis zum eingegebenen Ziel enthält, möglich. Bis eine Datenübertragung vollständig abgeschlossen ist, entstehen Totzeiten, die sowohl beim Start einer Route, aber auch bei Abweichung und Neugenerierung der Route auftreten können. Bei langen Routen oder einer hohen Informationsdichte kann dieser Prozess einige Minuten in Anspruch nehmen. In dieser Zeit ist eine Berechnung auf Basis der Daten nur unvollständig oder gar nicht möglich.

3.5.3. Dynamische Karteninhalte

Dynamische Karteninhalte ergänzen statische Kartenstrukturen durch aktuelle Informationen wie z. B. die aktuell gefahrene Geschwindigkeit sowie die Fahrzeit auf einem bestimmten Segment der Route. Die beiden führenden Firmen, die Verkehrsflussdaten³² (TFD) sammeln und als Produkt anbieten sind TOMTOM und INRIX. Je nach Anwendung gibt es unterschiedliche Verfahren, wie einzelne Positionsmessungen³³ gesammelt und an mobile Einheiten übertragen werden können, die im Folgenden beschrieben werden.

Verkehrsfluss und Stauinformationen in Echtzeit

Traffic Message Channel (TMC) [171] ist das meist verbreitetste Verfahren, um aktuelle Verkehrsinformation als digitalen Dienst über ein Radio Data System (RDS) zu verschicken. Die übermittelten Meldungen bestehen aus einem Ereigniscode mit 1460 Ereignissen und einem Lagecode³⁴ und sind nach dem Alert C-Standard kodiert [4].

³¹ engl. Most Probable Path

³² engl. Traffic Flow Data

³³ engl. Probes

³⁴ engl. Location Code

Der Lagecode wird länderspezifisch über eine Lagecodelist³⁵ referenziert. Diese statischen TMC Codes beschreiben Streckenabschnitte in Karten und decken mit einer Anzahl von 46390 (Stand: November 2013) Segmenten in Deutschland größtenteils nur Bundesautobahnen und Bundesstraßen ab.

Da die Lagecodes national verwaltet werden und dadurch vorkodiert werden müssen, ist die Anzahl von übertragbaren Lageinformationen begrenzt.

Der OPENLRTM-Standard stellt eine Weiterentwicklung des TMCs dar. Er wurde als freier Standard von TOMTOM entwickelt, der unabhängig der verwendeten Karten Abläufe und Formate anbietet, die beim Kodieren, Übermitteln und Dekodieren von positionsreferenzierten Daten notwendig sind. Durch eine dynamische Generierung der Positionsreferenzierung können selbst kleine Straßen abgebildet werden [5].

Verkehrsdatsammlung: Datenlieferanten benutzen eine Vielzahl unterschiedlicher Quellen, um Verkehrsdaten zu sammeln. Darunter befinden sich die traditionellen Methoden wie Induktionsschleifen, Verkehrskameras und Infrarotsensoren, die qualitativ hochwertige Daten liefern. Nachteile dieser stationären Vorrichtungen sind die Kosten für die Installation und Erhaltung, die benötigte Kalibrierung der Systeme sowie die fehlende Möglichkeit Reisezeiten zu messen [7].

Als neue Technologie bietet Floating Car Data (FCD) die Möglichkeit, aktuelle Geschwindigkeiten und Reisezeiten zu messen. Dabei wird unterschieden, ob einzelne Messungen aus dem Telekommunikationsnetz oder direkt aus GPS Informationen gewonnen werden.

Cellular Floating Phone Data (CFPD) [11] ist eines der Verfahren, bei dem Positionsdaten von jedem Mobiltelefon eines Anbieters anonymisiert in die Verkehrsflussberechnung einfließen. Damit das Mobiltelefon im Falle eines Anrufs der richtigen Basisstation zugewiesen wird, bzw. während eines Anrufs an weitere Stationen weitergereicht werden kann (Handover), wird durch eine sogenannte Timing Advance (TA) Messung der Abstand zu den relevanten Basisstationen bestimmt. Durch Triangulation mehrerer TAs zu unterschiedlichen Basisstationen lässt sich so die exakte Position des Mobiltelefons und damit auch seine Bewegung bestimmen. Eine Filterung der Daten ist notwendig, um nur solche Messungen zu betrachten, die einem Fahrzeug auf dem Straßennetz zuzuweisen sind [8].

Bei einer zunehmend flächendeckenden Verfügbarkeit von GPS-fähigen Endgeräten fällt die aufwendige Filterung der CFPD vor allem in Städten weg. Über einen bidirektionalen GPRS³⁶ Kommunikationskanal werden zum einen Positionsinformationen abgerufen, aber auch neue Updates für die betrachtete Route in einer Updaterate von wenigen Minuten übertragen [8].

³⁵ Die Lagecodelist^e (engl. Location Code List) für Deutschland kann bei der Bundesanstalt für Straßenwesen beantragt werden (www.bast.de)

³⁶ General Packet Radio Service (GPRS) ist ein paketorientierter Dienst zur Datenübertragung

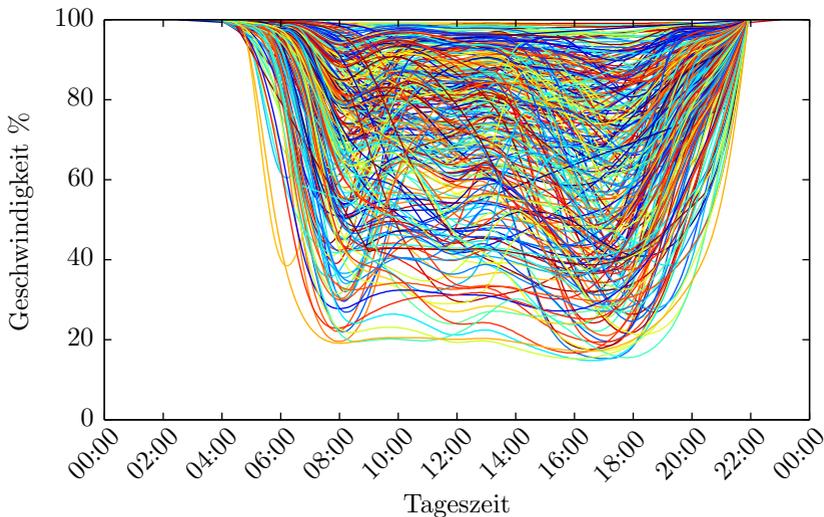


Abb. 3.5.: Geschwindigkeitsprofile als prozentualer Anteil der Free Flow Geschwindigkeiten bei IQ ROUTES™nach [7]

Produkte: TOMTOM bietet seinen Kunden mit dem kostenpflichtigen Produkt HD TRAFFIC™ ein Update alle zwei Minuten bei einer Abdeckungsrate der Straßen von über 99 % und einer durchschnittlichen Zeitersparnis von 18,5 % [6] an. Die Segmente sind zwischen einem und weniger als zwei Kilometern lang [7]. INRIX XD™TRAFFIC ist in 40 Ländern verfügbar und löst bei einer Abdeckung von über 6,4 Millionen Kilometer Straßensegmente bis zu 10 Meter³⁷ genau auf [3].

Verkehrsprädiktion aus historischen Daten

Das positionsgenaue Sammeln und Verarbeiten aller Daten ermöglicht die Verkehrsprädiktion für zukünftige Flussgeschwindigkeiten und potenzielles Auftreten von Staus. TOMTOMS Datenbank mit historischen Geschwindigkeitsmessungen umfasst 6 Trillionen Messungen, die seit 2008 gesammelt werden. Jeden Tag kommen 6 Millionen neue Messungen dazu [7].

Unter dem Produktname IQ ROUTES™(IQR) werden Geschwindigkeitsprofile für jedes Kartensegment erstellt. Diese Geschwindigkeitsprofile stellen die prozentuale Abweichung zur gefahrenen Geschwindigkeit bei Nacht (Free Flow) dar und sind im 5-Minutenraster über den Tag aufgeschlüsselt. Jeder Tag der Woche ist in einem eigenen Profil charakterisiert.

³⁷ Im Vergleich zu 2-5 Kilometern bei TMC

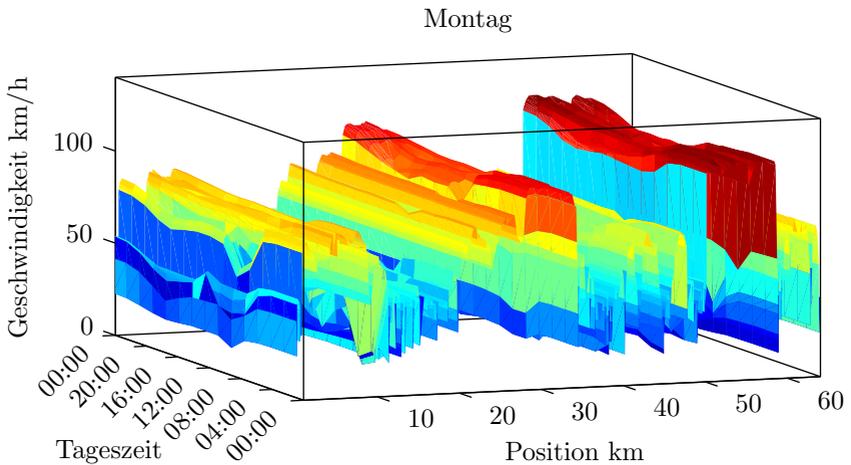


Abb. 3.6.: Verkehrsprädiktionsmodell aus IQR Profilen für die Stuttgart-Runde exemplarisch für einen Arbeitstag (Montag)

Zur Reduktion der Daten werden alle Geschwindigkeitsprofile in nur 100 Standardprofilen prozentual dargestellt. Diese haben eine eindeutige ID, mit der einem Segment ein passendes Profil zugewiesen wird. In Abb. 3.5 sind die verwendeten Profile dargestellt. Viele der Profile weisen eine starke Geschwindigkeitsreduktion morgens (8 Uhr) und nachmittags (17 Uhr) auf und bilden so den Berufsverkehr deutlich ab.

Alle Profile für jedes Segment auf der Stuttgart-Runde sind in Abb. 3.6 für einen Montag abgebildet. Dabei sind die Profile mit der Free Flow Geschwindigkeit verrechnet, wodurch die absolute Geschwindigkeit über Zeit und Strecke dargestellt ist.

Die Profile werden für jedes Land mit einem vierteljährlichen Update der Karten aktualisiert. Dabei werden die zurückliegende 24 Monate in der Zuweisung der Profile berücksichtigt [7].

3.5.4. Automatische Routenerkennung

Für prädiktive Energiemanagementsysteme ist die Route entscheidend. Gerade für die Blending Strategie ist die Routeninformation bis zum Ziel unumgänglich. Es gibt zwei Möglichkeiten eine Route zu identifizieren: Der Fahrer gibt das Ziel in die Navigation ein oder es erfolgt eine Routenerkennung auf Basis historischer Fahrten. Für kurze, bekannte Strecken wird ein Fahrer oft keine Navigation verwenden. Aber gerade diese Strecken werden öfter gefahren und können so identifiziert werden.

In [102] wird ein Algorithmus aus der Bildverarbeitung verwendet, der über die normierte zweidimensionale Kreuzkorrelation zwischen der aktuellen GPS Trajektorie und gespeicherten Trajektorien die Route schätzt. Dabei ist keine digitale Karte notwendig, da nur GPS Verläufe und Uhrzeiten einer Fahrt gespeichert und miteinander verglichen werden. Verlaufen Routen anfänglich über dieselben Streckenabschnitte und teilen sich erst danach, kann eine Unterscheidung nur durch die Uhrzeit erfolgen. Die Routen werden in der Studie erfolgreich in realen Messungen identifiziert.

In einer weiteren Arbeit werden die Routen von 240 Fahrern im Schnitt 15 Tage beobachtet. Dabei werden 14468 verwertbare Fahrten ausgewertet. 39,3 % der Fahrten sind Wiederholungsfahrten. Zur automatischen Routenerkennung werden Algorithmen zur Ähnlichkeitserkennung und eine Clusteranalyse herangezogen [59].

3.6. Positionierung der Arbeit

Die Optimierung des Energiemanagements für Hybridfahrzeuge wurde durch eine Vielzahl von wissenschaftlichen Arbeiten betrachtet. Die Dynamische Programmierung garantiert als eine der numerischen Berechnungsmethoden optimale Strategien, wird aber oft nur in der Simulation zu Referenzzwecken und selten in einer echtzeitfähigen Regelung verwendet. In der vorliegenden Arbeit werden mehrere Methoden vorgestellt, die es erlauben, eine optimale Fahrstrategie und eine optimale Energiemanagementstrategie mit Hilfe der Dynamischen Programmierung zu berechnen. Dabei werden iterative, approximierte und heuristische Verfahren mit dem Grundprinzip der Dynamischen Programmierung verknüpft und erlauben so eine echtzeitfähige Anwendung.

Eine gemeinsame Optimierung der Fahrstrategie und Energiemanagementstrategie ist durch die erarbeiteten Methoden möglich und ist so in der Literatur nicht zu finden. Die dadurch entstehenden Potenziale sowie ein Vergleich zu einer getrennten Optimierung werden in der Simulation ausgiebig untersucht.

Das Prinzip der Modellbasierten Prädiktiven Regelung (MPC) eines HEVs aus der Arbeit von BACK [12] wird aufgegriffen und durch einen mehrstufigen Aufbau erweitert, sodass durch die Parallelisierung der Strategieoptimierung ein performantes Fahrerassistenzsystem für Hybridfahrzeuge entsteht, das sowohl effizient plant als auch effizient regelt.

Entscheidend für eine robuste Regelung eines prädiktiven Energiemanagements ist die Güte der Leistungsprädiktion. Alle in der Literaturrecherche vorgestellten Arbeiten zur Leistungsprädiktion im Realbetrieb führen Untersuchungen auf Basis von Fahrzyklen durch, die auf rein statischen digitalen Karten beruhen. In der vorliegenden Arbeit werden erstmalig hochaktuelle dynamische Kartenattribute sowie Verkehrsprädiktionsmodelle aus der Navigation für die Optimierung des Energiemanagements bis zum Reiseziel verwendet.

Die Betrachtung unterschiedlicher Routen in Simulation und Fahrversuch ermöglichen eine realitätsnahe Untersuchung der Potenziale eines Plug-in Hybridfahrzeugs in Längsregelung und Freifahrt.

4. Optimale Modellprädiktive Regelung

Ein dynamisches System beschreibt nach FÖLLINGER [57] einen technischen Prozess, *der als eine Gesamtheit von veränderlichen Größen verstanden werden kann, die durch Funktionalbeziehungen wie Differenzialgleichungen, Differenzengleichungen und dergleichen miteinander verknüpft sind.*

Ein dynamisches System wird in der Regelungstechnik im Allgemeinen als Regelstrecke bezeichnet, die für die Aufgabenstellung hinreichend gut modelliert ist.

In der Zustandsbeschreibung lassen sich die Komponenten eines dynamischen Systems durch die Vektorschreibweise darstellen. Mehrdimensionale Größen sind durch eine Unterstreichung gekennzeichnet. \underline{x} repräsentiert den Zustandsvektor, \underline{u} den Steuervektor, und \underline{y} den Ausgangsvektor. Als Zustandsgleichungen sind die Zustandsdifferenzialgleichung $\dot{\underline{x}}$ und die Ausgangsgleichung \underline{y} zusammengefasst, die das dynamische System beschreiben (siehe Abb. 4.1).

Während bei einem klassischen Reglerentwurf einzelne Kenngrößen des Regelkreises an vorgegebene Forderungen angepasst werden, soll bei der optimalen Regelung der gesamte Verlauf der Stell- und Regelgrößen optimiert werden [111]. Es wird ein Gütemaß J für die Güte des Regelkreises herangezogen, das durch optimale Steuergrößen $\underline{u}^*(t)$ über den Verlauf minimiert wird. Das dynamische Optimierungsproblem lässt sich wie folgt formulieren:

$$\min_{\underline{u}(t)} J(\underline{x}_0, \underline{u}(t)) = J(\underline{x}_0, \underline{u}^*(t)). \quad (4.1)$$

Zur Lösung des Optimierungsproblems werden Verfahren verwendet, die in Abschnitt 3.2.2 vorgestellt werden. Für ein lineares, zeitvariables System wird eine optimale Zustandsrückführung vereinfacht in einer optimalen Regelmatrix K^* dargestellt (siehe Abb. 4.1).

Der optimale Steuervektor \underline{u}^* sowie der optimale Zustandsvektor \underline{x}^* werden im Folgenden durch einen Stern gekennzeichnet.

4.1. Gütemaße einer optimalen Regelung

Das Gütemaß ist bei der Suche nach einer optimalen Regelung wesentlicher Bestandteil des Reglerentwurfs. Es wird auf die Form der Lösung angepasst und hat dadurch einen

entscheidenden Einfluss, ob eine Lösung existiert bzw. wie gut ein Ergebnis ausfällt. Eine optimale Lösung ist dadurch immer im Bezug zum verwendeten Gütemaß zu verstehen. Bei einem Gütemaß werden Abweichungen zu einem gewünschten Ideal mit einem Wert verknüpft. Da diese Werte funktional abgebildet werden können, spricht man auch von einer Kostenfunktion, bei der die Kosten die Abweichung bewerten. Im Folgenden wird auf verschiedene Gütemaße eingegangen, die unterschiedliche Zielsetzungen verfolgen.

Energieoptimales Gütemaß

Wird ein dynamisches System aus rein energetischen Gesichtspunkten betrachtet, so beeinflusst allein der Steuervektor $u(t)$, ob Energie aus dem System heraus oder hinein fließt. Die zugeführte Gesamtenergie lässt sich demzufolge über das Integral des Steuervektors definieren.

$$J = \int_{t_0}^{t_e} u^2(t) dt \quad (4.2)$$

Dabei wird die quadratische Regelfläche betrachtet, um Vorzeicheneinflüsse auszuschließen und große Steuergrößen zu bestrafen.

Verlaufoptimales Gütemaß

Soll ein Anfangszustand \underline{x}_0 ohne große Zustandsabweichungen in einen Endzustand \underline{x}_e überführt werden, spricht man von einem verlaufoptimalen Gütemaß. Ähnlich wie beim energieoptimalen Gütemaß wird hier der Zustand im Quadrat integriert.

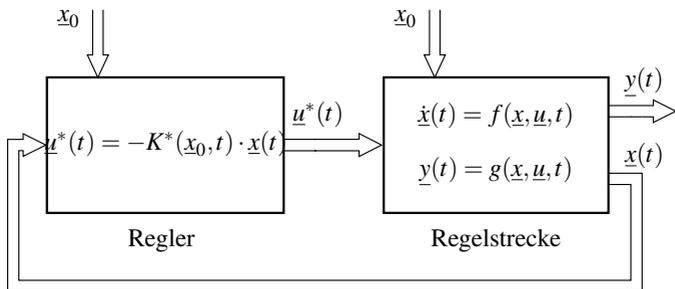


Abb. 4.1.: Optimale Regelung eines dynamischen Systems

Handelt es sich dabei um einen mehrdimensionalen Zustandsvektor \underline{x} , lässt sich das Gütemaß in der Vektorschreibweise schreiben:

$$J = \int_{t_0}^{t_e} \underline{x}^\top \underline{Q} \underline{x} dt = \int_{t_0}^{t_e} [x_1 \quad \dots \quad x_n]^\top \begin{bmatrix} q_1 & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & q_n \end{bmatrix} \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix} dt \quad (4.3)$$

\underline{Q} ist eine symmetrische, positiv semidefinite Matrix, die die Zustände zueinander gewichtet. Die Gewichtung ermöglicht es, unterschiedliche Zustandsvariablen miteinander zu vergleichen bzw. einzelne durch eine stärkere Gewichtung herauszuheben. Wird nach einer energieoptimalen und gleichzeitig verlaufsoptimalen Lösung gesucht, lassen sich beide Anforderungen in einem Gütemaß verbinden.

$$J = \int_{t_0}^{t_e} \underline{x}^\top \underline{Q} \underline{x} + \underline{u}^\top \underline{R} \underline{u} dt. \quad (4.4)$$

\underline{R} ist dabei eine Gewichtungsmatrix für den Steuervektor \underline{u} . Je nach Parametrierung von \underline{Q} und \underline{R} wird die Energie oder der Verlauf stärker gewichtet.

Zeitoptimales Gütemaß

Soll das System in möglichst kurzer Zeit im Zielzustand sein, spricht man vom zeitoptimalen Gütemaß, das auch als Zeitdifferenz zwischen Anfangs- und Endzeit geschrieben werden kann.

$$J = t_e - t_0 = \int_{t_0}^{t_e} 1 dt \quad (4.5)$$

Erfolgt die Optimierung nicht in kontinuierlicher Zeit, sondern diskreten äquidistanten Wegstücken und geht man von einem linearen Geschwindigkeitsübergang aus, lässt sich ein zeitoptimales Gütemaß wie folgt bestimmen:

$$J = \sum_{k=0}^N \frac{\Delta s_k}{v_k}, \quad \text{für } k = 0, 1, \dots, N. \quad (4.6)$$

Da alle bisher genannten Gütemaße ein Optimierungsproblem unter Berücksichtigung von Differenzialgleichungen als Nebenbedingungen minimieren, nennt man diese Gütemaße auch LAGRANGESche Gütemaße [56].

$$J = \int_{t_0}^{t_e} f(\underline{x}(t), \underline{u}(t), \underline{z}(t), t) dt \quad (4.7)$$

Ist nicht nur das Übergangsverhalten zwischen t_0 und t_e , sondern auch das Endverhalten von Bedeutung, lässt sich dieses im MAYERSchen Gütemaß ausdrücken:

$$J = h(\underline{x}(t_e), t_e) \quad (4.8)$$

Als Beispiel dient hierfür ein gewünschter Zustand des Fahrzeugs, der durch die Geschwindigkeit und die Batterieladung definiert sein kann. Über dieses Gütemaß wird die Abweichung zu diesem Zustand gewichtet.

BOLZASches Gütemaß

Vereint man das MAYERSche und das LAGRANGESche Gütemaß in einem, um eine möglichst allgemeine Bewertung des dynamischen Verhaltens darzustellen, spricht man vom BOLZASchen Gütemaß [56]:

$$J = h(\underline{x}(t_e), t_e) + \int_{t_0}^{t_e} f(\underline{x}(t), \underline{u}(t), \underline{z}(t), t) dt \quad (4.9)$$

Diskrete Schrittweite

In der numerischen Umsetzung wird die Optimierungsaufgabe in zeit- oder wegdiskreten Schritten durchlaufen, sodass das LAGRANGESche Gütemaß wie folgt definiert werden kann:

$$J = \sum_{k=0}^N f(x_k, u_k, z_k, k) \quad \text{für } k = 0, 1, \dots, N. \quad (4.10)$$

Wird das Intervall $\Delta s' = \Delta s'' = k_{i+1} - k_i$ (siehe Abb. 4.2) äquidistant gewählt, gehen die Kosten in jedem Schritt gleichverteilt in die Summenrechnung ein. Bei variabler Schrittweite ist zwischen einem diskretisierungsabhängigen und -unabhängigen Gütemaß zu unterscheiden [184]:

Beim diskretisierungsunabhängigen Gütemaß wird allein der Zustand an der Stelle k bewertet. Als Beispiel für ein zeitoptimales, diskretisierungsunabhängiges Gütemaß wird die Abweichung der aktuellen Geschwindigkeit von einer maximalen Referenzgeschwindigkeit gewählt (siehe Gl. (4.11)). Bei äquidistanter Wegdiskretisierung ist so eine indirekte Bewertung der Zeit möglich.

$$J^V = \sum_{k=0}^N v_{\max,k} - v_k, \quad \text{für } k = 0, 1, \dots, N \text{ und } \Delta s = \text{const.} \quad (4.11)$$

Passt man in diesem Beispiel die Wegdiskretisierung an die vorhandene Information über eine erlaubte maximale Geschwindigkeit an, die nicht äquidistant vorliegt, ist ein diskretisierungsabhängiges Gütemaß notwendig, das den Einfluss der unterschiedlichen Weglängen in die Kosten an jedem Abschnitt k einfließen lässt. Das Prinzip wird am folgenden Beispiel skizziert:

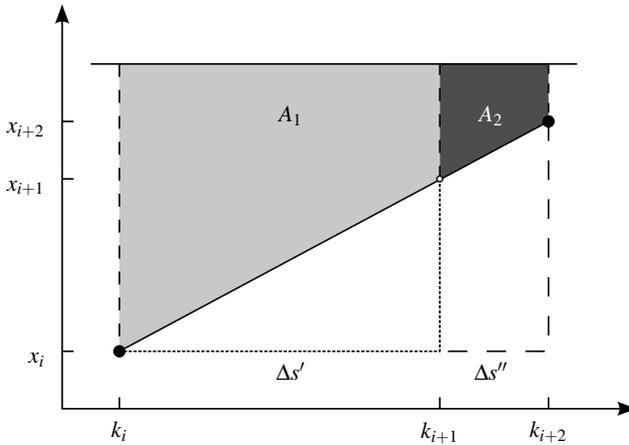


Abb. 4.2.: Diskretisierungsabhängiges Gütemaß

Fügt man eine Stützstelle zwischen zwei Zuständen x_i und x_{i+2} ein, so müssen die Übergangskosten auf die Wegstrecke $\Delta s'$ normiert und entsprechend der Form des Zustandsübergangs gewichtet werden. Bei der Annahme eines linearen Zustandsübergangs werden die Kosten linear mit $\Delta s'$ gewichtet. Ein zeitoptimales diskretisierungsabhängiges Gütemaß kann wie folgt dargestellt werden:

$$J^T = \sum_{k=0}^N \left| \frac{t_{\min,k} - t_k}{\Delta s_k} \right|^p \cdot \Delta s_k, \quad \text{für } k = 0, 1, \dots, N \text{ und } p \in \mathbb{N}^*. \quad (4.12)$$

Die minimale Zeit $t_{\min,k}$ bei einem Zustandsübergang von k_i zu k_{i+1} wird als Referenz verwendet. Die Gewichtung p kann je nach Stärke der Bestrafung der Abweichung gewählt werden. Bevorzugt wird die quadratische Funktion mit $p = 2$ verwendet.

4.1.1. Normierte Kosten

Werden in einem Gütemaß verschiedene Kriterien berücksichtigt, deren physikalische Einheiten sich unterscheiden, ist eine Normierung der einzelnen Kriterien sinnvoll. Für die in Kap. 6 beschriebene Regelung werden drei Kriterien betrachtet:

Energetische Kosten

Bei HEVs wird wie bei konventionellen Fahrzeugen der Kraftstoffverbrauch allein zur Bewertung der energetischen Kosten herangezogen, da elektrische Energie nur während der Fahrt umgesetzt wird. Der Kraftstoff ist damit die alleinige nachfüllbare Energieressource zu Beginn der Fahrt, mit der monetäre Kosten verbunden sind.

Bei PHEVs kann die Batterie zu Beginn der Fahrt extern geladen werden, wodurch ebenso monetäre Kosten anfallen. Das Gütemaß für die Energie in jedem Schritt k kann demzufolge als Addition aus der benötigten chemischen Energie $E_{\text{chem},k}$ und der elektrischen Energie $E_{\text{el},k}$ zusammengesetzt werden:

$$J_k^{E1} = E_{\text{chem},k} + E_{\text{el},k} = P_{\text{chem},k} \cdot \Delta t + P_{\text{el},k} \cdot \Delta t \in \mathbb{R} \quad (4.13)$$

In einem anderen Ansatz bewertet man die Umsetzung der getankten und geladenen Energie in kinetische Energie. Die energetischen Kosten stellen somit den Gesamtwirkungsgrad des Fahrzeugs in jedem Schritt k dar. Das Gütemaß wird durch das Verhältnis der zurückgeführten Energie E_k^+ zur investierten Energie E_k^- bestimmt [176]:

$$J_k^{|E2|} = 1 - \eta_{\text{ges},k} = 1 - \frac{E_k^+}{E_k^-} \in [0, 1] \quad (4.14)$$

Da sich der Aufbau der zurückgeführten und investierten Energien je nach Hybridmodus unterscheiden kann, sind zur Berechnung der Energien Fallunterscheidungen notwendig.

Zeitliche Kosten

Die Geschwindigkeit entscheidet über die benötigte Zeit für einen Distanzschritt. Die Normierung erfolgt anhand der kleinsten Zeitspanne, die wiederum bei maximal möglicher Geschwindigkeit $v_{\text{max},k}$ in einem Schritt erreicht werden kann. Das normierte Gütemaß für die Zeit bestraft somit Abweichungen von der kürzesten Fahrzeit:

$$J_k^{|T|} = 1 - \frac{v_k}{v_{\text{max},k}} \in [0, 1] \quad (4.15)$$

Komfortkosten

Die energetischen und zeitlichen Kosten reichen nicht aus, um eine Fahrbarkeit und Akzeptanz der resultierenden Regelung zu gewährleisten. Es sind daher Komfortkriterien notwendig, die Zustandsübergänge bestrafen oder ganz ausschließen. Um einen glatten Geschwindigkeitsverlauf zu erhalten, wird der Ruck als Ableitung der Beschleunigung als eines der Gütemaße für den Komfort verwendet. Dabei erfolgt die Normierung über einen maximal erlaubten Ruck Jerk_{max} :

$$J_k^{|K1|} = \frac{\left| \frac{\Delta a_k}{\Delta t_k} \right|}{\text{Jerk}_{\text{max}}} \in [0, 1] \quad (4.16)$$

Häufige Gangwechsel sowie Motorstartvorgänge können theoretisch als optimal gelten, sind jedoch im Fahrzeug nicht realisierbar und vom Fahrzeuginsassen nicht erwünscht. Über ein weiteres Gütemaß für den Komfort werden diese Übergänge bestraft:

$$J_k^{|K2|} = \begin{cases} 1, & \text{falls unerwünschter Übergang} \\ 0, & \text{sonst.} \end{cases} \quad (4.17)$$

4.2. Modellbasierte Prädiktive Regelung (MPC)

In der industriellen Regelungstechnik wird ein Großteil der Steuerprobleme von Prozessen mit konventionellen PID-Regelungen gelöst. Dabei wird der Prozess vereinfacht in Modellen abgebildet, die wiederum zur Auslegung einer Regelung dienen. Dabei ist zwischen empirischen und theoretischen Modellen zu unterscheiden. Vorteil dieser PID-Regelung ist die einfache und für den Ingenieur nachvollziehbare Parametrierung sowie eine schnelle, echtzeitfähige Umsetzung für den Realbetrieb.

Bei der Modellbasierten Prädiktiven Regelung³⁸ (MPC) wird das erarbeitete Modellwissen über den technischen dynamischen Prozess in die Regelung nicht nur zum Entwurf und Einstellung bestimmter Parameter, sondern als eine Komponente zur Prädiktion eines vorausliegenden Verhaltens im laufenden Betrieb integriert [40]. Die Umsetzung erfolgt über einen Mikrocontroller.

Die Modellierung des dynamischen Verhaltens der Regelstrecke hat entscheidende Auswirkung auf die Güte der Regelung. Ist die Modellgüte im idealen Fall so hoch, dass sie die vorausliegende Dynamik exakt präzisieren kann, reicht eine Steuerung zur Umsetzung der berechneten Steuergrößen.

Das Ziel ist eine hohe Modellgüte und führt zu einer hohen Robustheit der Regelung. Modelle dieser Art sind meist komplex und rechenintensiv. In hochdynamischen Prozessen ist jedoch eine schnelle Reaktion und ein schnelles Prädiktionsverhalten notwendig. Eine schnelle und präzise Optimierung ist das Ziel jeder echtzeitfähigen MPC-Regelung.

4.2.1. MPC in der Fahrzeugführung

Das Prinzip der MPC wurde in einigen Arbeiten erfolgreich in der Fahrzeugführung verwendet. BACK [12] verwendet das MPC Prinzip zur Umsetzung optimaler Energiemanagementstrategien in einem seriellen Hybridfahrzeug, während TERWEN [166] die optimale Geschwindigkeit und Gangwahl von LKWs mit Hilfe der MPC in Längsführung regelt.

In Abb. 4.3 ist das Grundprinzip der MPC für eine einfache Geschwindigkeitsregelung dargestellt. Der MPC-Regler beobachtet den zurückliegenden und aktuellen Systemzustand x sowie die historischen Steuergrößen u .

³⁸ engl. Model Predictive Control

Die Prozessdynamik ist in Form eines Modells dem Regler vorliegend, wodurch ein Verhalten für die vorausliegende Strecke prädiziert werden kann. Dabei können verschiedene Steuergrößenfolgen in einer Art Simulation berechnet und miteinander verglichen werden. Durch den Vergleich aller möglichen Steuervariationen kann ein optimaler Verlauf der Regelgrößen für den aktuellen Zustand x_{ist} bestimmt werden. Nebenbedingungen wie z. B. die maximale Änderungen der Steuergrößen Δu_{max} werden in der Optimierung und somit auch in der Steuerung berücksichtigt. Der Steuerhorizont mit N_c Schritten wird je nach Berechnungszeit der Optimierung möglichst kurz gewählt, während die Länge des Prädiktionshorizonts entscheidend für die Optimalität der Regelung ist. Wird wie in Abb. 4.3 gezeigt der Prädiktionshorizont 1 zu kurz gewählt, so wird eine Geschwindigkeitsreduktion, die durch eine Kurve entsteht, nicht berücksichtigt. Bei einem längeren Prädiktionshorizont 2 mit N_{p2} Schritten, wird die Kurve als Störgröße und im optimalen Verlauf der Regelgrößen berücksichtigt. Die Länge des Prädiktionshorizonts und die Anzahl der Stützstellen $N - 1$ haben je nach Komplexität des Systems große Auswirkungen auf die Berechnung der Optimierung.

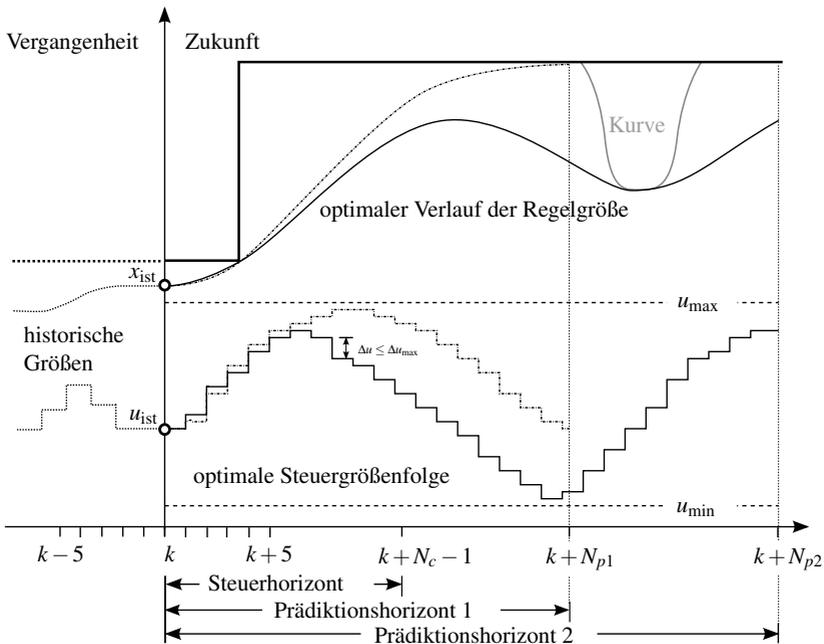


Abb. 4.3.: Grundprinzip der MPC nach [40]

Prinzip des gleitenden Horizonts

Das Modell kann die Prozessdynamik im Realverhalten nur annähernd abbilden, da einerseits ein sehr präzises Modell und die Variationsrechnung zu rechenintensiv ausfallen würde und andererseits Modellfehler durch fehlende oder fehleranfällige Sensorik auftreten. Der Steuerhorizont ist demzufolge möglichst kurz zu wählen. Sobald eine Neuberechnung der Prädiktion und Optimierung erfolgt, liegen aktuelle Steuergrößen vor; im idealen Fall in jedem Abtastintervall. Da der betrachtete Horizont bei jeder Ausführung um ein Abtastintervall verschoben wird, spricht man von einem gleitenden Horizont [40]. Der aktuelle Zustand x_{ist} wird fortlaufend mit einbezogen, wodurch ein geschlossener Regelkreis entsteht.

Dynamische Optimierung

Kern eines jeden MPC-Reglers ist die Lösung eines Optimierungsproblems über einen vorgegebenen Prädiktionshorizont, wobei ein Gütemaß der Optimierung die Regelgüte und meist auch die Stellaktivität bewertet. Die Optimierung kann sowohl analytisch als auch numerisch berechnet werden (siehe Abschnitt 3.2.2). Das Ergebnis der dynamischen Optimierung ist eine optimale Steuergrößenfolge für den Prädiktionshorizont unter der Berücksichtigung aller Nebenbedingungen. Die Dynamische Programmierung wird als numerisches Verfahren in dieser Arbeit zur Optimierung herangezogen. Da für lineare dynamische Systeme der Riccati-Regler ein optimales Regelverhalten darstellt, kann die Optimalität über diesen Reglertyp bewiesen werden. Ein Beweis der optimalen Regelung einer Batteriezustandsplanung für ein linearisiertes System durch die Überführung der DP in die Riccati-Gleichung ist in Anhang A.7 zu finden.

4.2.2. Nichtlineare Modellbasierte Prädiktive Regelung (NMPC)

In vielen Fällen ist das Modell in der MPC nicht oder nicht vollständig linearisierbar. Man spricht deshalb von der Nichtlinearen Modellbasierten Prädiktiven Regelung³⁹ (NMPC), wobei als wesentlicher Unterschied die Konvexität des Optimierungsproblems verloren geht [116]. Eine Vielzahl von Lösungsalgorithmen stehen dabei zur Verfügung, die es ermöglichen auch bei lokalen Minima das globale Optimum zu finden [53][12].

Die Regelstrecke für eine zeit- und energieoptimale Strategie eines Hybridfahrzeugs weist Nichtlinearitäten auf, wodurch ein nichtlineares Systemmodell verwendet wird. Wie in [12] wird daher das NMPC-Prinzip für die Regelung herangezogen, wobei zur Regelung des Energiemanagements die Betrachtung der optimalen Längsführung ergänzt wird. Durch eine im Vergleich zu [12] deutlich größere Batterie des Versuchsträgers sowie der Mehrdimensionalität des Optimierungsproblems durch Hinzunahme der Längsregelung, ist die Berechnung sehr aufwendig und rechenintensiv.

³⁹ engl. Nonlinear Model Predictive Control

Die Größe der Batterie und die damit verbundene erhöhte Reichweite verlangt einen Prädiktionshorizont bis zum Fahrtziel. Ein mehrdimensionaler Zustandsraum, der sowohl das Energiemanagement als auch die Längsführung abdeckt und bis zum Fahrtziel rechnet, erfordert einen sehr großen Speicher und eine hohe Rechenzeit der Optimierung. Die Berechnungszeit liegt selbst bei performanten Prozessoren über der Zeit eines Abtastschritts, der für eine echtzeitfähige Regelung notwendig ist.

4.3. Echtzeitfähigkeit durch Parallelisierung

Echtzeitfähigkeit der NMPC-Regelung ist gewährleistet, wenn zu jedem Abtastzeitpunkt Steuergrößen vorliegen. Für eine optimale Regelung muss daher die Optimierung schnell genug erfolgen. Um alle für die Optimierung relevanten Einflüsse bis zum Fahrtziel zu berücksichtigen sowie die Rechenzeit auf die Abtastzeit zu reduzieren, werden in einem neuen Ansatz mehrere Berechnungen parallel ausgeführt. Jede dieser Berechnung erfolgt über unterschiedlich lange Prädiktionshorizonte und wird in parallelen Tasks mit unterschiedlichen Zykluszeiten ausgeführt, wobei die Zykluszeit bei längerem Horizont zunimmt. Die NMPC-Regelung erfolgt somit zeitlich kaskadiert.

In Abb. 4.4 ist eine kaskadierte NMPC-Regelung mit drei parallelen Tasks schematisch im Zustandsraum abgebildet. TASK 1 berechnet den optimalen Verlauf der Regelgröße über einen langen Prädiktionshorizont mit N_{p1} Schritten und wird deshalb in einer langen Zykluszeit ausgeführt. Sobald ein optimales Ergebnis von TASK 1 vorliegt (k_2) wird dieses im TASK 2 über den kürzeren Prädiktionshorizont mit N_{p2} als Zielgröße verwendet. Die Nebenbedingungen der Optimierung können sich in der Zwischenzeit verändern (siehe Obj_1), sodass diese in den Tasks mit der höheren Updaterate berücksichtigt werden können. Soweit die Zielvorgabe am Ende des Prädiktionshorizonts des ersten Tasks erreichbar ist, wird diese weiterhin verfolgt, da dadurch Informationen aus einem längeren Horizont auch bei den unterlagerten Tasks (TASK 2 und TASK 3) berücksichtigt werden können.

TASK 3 wird im Zyklus einer Abtastzeit ausgeführt und gewährleistet somit ein deterministisches Regelverhalten. Der kurze Prädiktionshorizont über N_{p3} Schritte orientiert sich dabei an den Verläufen aus den überlagerten Tasks, soweit diese vorliegen und aktualisierte Informationen enthalten. Ist dies nicht der Fall (k_3), da z. B. ein weiteres Objekt (Obj_2) auftritt und die überlagerten Vorgaben nicht möglich sind, kann nur ein optimaler Verlauf der Regelgrößen über den kurzen Prädiktionshorizont erfolgen.

In einem neuen Zyklus werden die Optimierungen in jedem Task von dem aktuellen Zustand ausgeführt ($k'_1 = k_3 + N_{p3}$), womit jeder Task einen geschlossenen Regelkreis darstellt. Neue Randbedingungen (Obj_1 und Obj_2) werden, soweit sie auf dem jeweiligen Prädiktionshorizont relevant sind, bei jedem Update in den Tasks berücksichtigt.

Tasks mit hoher Updaterate (TASK 3) können wesentlich schneller auf die Dynamik der Randbedingungen reagieren, während Tasks mit einem Prädiktionshorizont bis zum Fahrtziel alle wichtigen Informationen auf der Strecke berücksichtigen und damit die unterlagerten Tasks an ihren jeweiligen Enden der Prädiktionshorizonte eine Zielvorgabe bieten. Optimalität und schnelles Regelverhalten ist somit über die gesamte Strecke gewährleistet.

Eine Koordination und Entscheidungsinstanz zwischen der Ausführung und Weiterverarbeitung der Ergebnisse der einzelnen Tasks ist notwendig und legt fest, in welcher Situation welche Informationen mit welcher Priorität versehen werden.

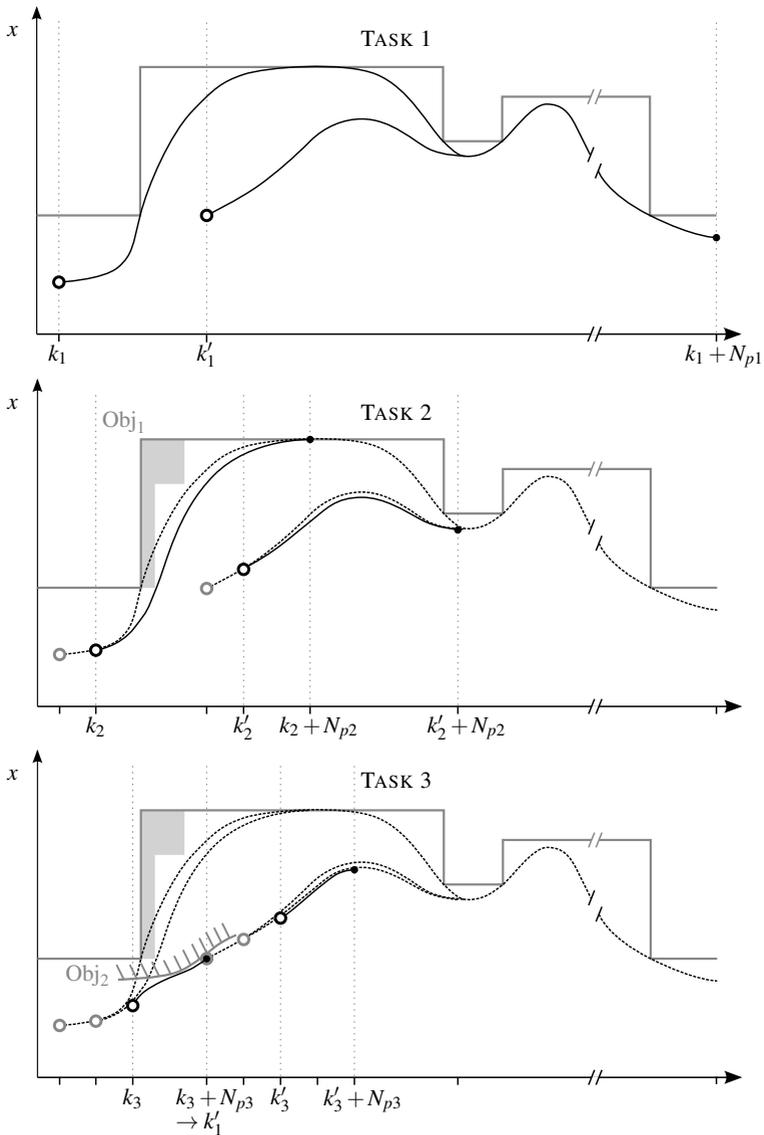


Abb. 4.4.: Schematischer Ablauf einer kaskadierten NMPC-Regelung mit drei parallelen Tasks mit unterschiedlichen Prädiktionshorizonten $N_{p1...3}$

5. Methoden zur Echtzeitoptimierung mittels Dynamischer Programmierung

Die Dynamische Programmierung (DP) stellt eine Methode dar, bei der komplexe Optimierungsprobleme in eine Anzahl von einfacheren Problemen aufgeteilt werden. Die Kombination der Lösungen dieser einfacheren Probleme führt zur Lösung des komplexen Optimierungsproblems. Je größer die Anzahl der einfacheren Probleme, desto größer ist die Wahrscheinlichkeit eine global optimale Lösung für das Optimierungsproblem unter den gegebenen Randbedingungen zu finden.

Um die DP anwenden zu können muss sich das Optimierungsproblem in aufeinander aufbauende Teilprobleme unterteilen lassen. Man spricht bei derartigen Optimierungsproblemen auch von mehrstufigen Entscheidungsprozessen.

5.1. Mehrstufige Entscheidungsprozesse

Mehrstufige Entscheidungsprozesse spannen alle Möglichkeiten beim Lösen eines Problems auf, indem die Auswirkung jeder Teilentscheidung festgehalten wird, um sie bei einer globalen Lösung zu berücksichtigen. Konsequenzen jeder einzelnen Entscheidung lassen sich in einem Entscheidungsbaum grafisch darstellen.

Beschreibt man ein physikalisches System durch einen mehrstufigen Entscheidungsprozess, lassen sich folgende Eigenschaften nach BELLMAN definieren [19] [96]:

- a.) Das physikalische System ist zu unterschiedlichen Zeiten (Stufen) betrachtbar.
- b.) Das System ist zu jedem Zeitpunkt durch eine Anzahl von Parametern, den Zustandsvariablen, charakterisiert, die jeweils die Konsequenz einer Entscheidung aus der vorangehenden Stufe beinhalten.
- c.) In jeder Stufe gibt es eine Anzahl von Entscheidungen.
- d.) Die Konsequenz der Entscheidung ist die Transformation der Zustandsvariablen.
- e.) Entscheidungen auf einer Stufe dürfen nicht mehr auf die schon betrachteten Stufen oder deren Zustände einwirken. Der Prozessablauf ist somit zum Prozessende hin gerichtet.

- f.) Der vergangene Verlauf des Systems hat keinen Einfluss auf die Festlegung der zukünftigen Handlungen.
- g.) Das Ziel des Prozesses ist die Maximierung bzw. Minimierung einiger Funktionen der Zustandsvariablen.

Es können prinzipiell zwei Arten von Prozessen unterschieden werden: Deterministische und stochastische mehrstufige Prozesse. Unter den stochastischen Prozessen stellen die MARKOVschen Entscheidungsprozesse eine Untergruppe dar.

Die hier genannten Eigenschaften eines mehrstufigen Entscheidungsprozesses können in den meisten Fällen als Voraussetzung zur Optimierung von Systemen mit der dynamischen Programmierung gesehen werden. Einschränkend gilt, dass nicht alle mehrstufigen Entscheidungsprozesse mit der DP gelöst werden können oder jede dynamische Programmieraufgabe mehrstufige Entscheidungsprobleme darstellt [96]. Die Aufteilung der Problemstellung in mehrere Teilprobleme ist die zentrale Voraussetzung zur Anwendung der DP.

Prozesse, die in dieser Arbeit betrachtet werden sind deterministische mehrstufige Entscheidungsprozesse, die dynamische Systeme beschreiben.

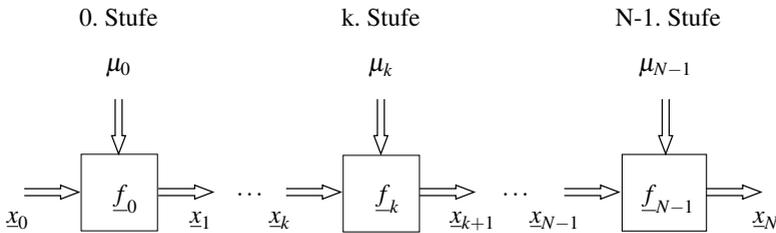


Abb. 5.1.: N-stufiger Entscheidungsprozess [56].

In Abb. 5.1 ist ein mehrstufiger Entscheidungsprozess mit N-Stufen schematisch dargestellt mit x_k als Zustandsvektor und f_k als Übertragungsfunktion. Um Entscheidungen in jeder Stufe treffen zu können, ist ein Gütemaß (siehe Abschnitt 4.1) notwendig, das einen Zustandsübergang sowie den Folgezustand durch Kosten bewertet.

5.1.1. Optimale Strategie

Eine Entscheidung in einer Stufe beinhaltet eine Aktion⁴⁰ μ_k , die z. B. einen Zustandsübergang auslösen kann. Die Abfolge dieser Aktionen nennt man Strategie⁴¹ π , wobei pro Stufe genau eine mögliche Aktion ausgewählt wird.

$$\pi = \{\mu_0, \mu_1, \dots, \mu_{N-1}\} \text{ für } \pi \in \Pi \quad (5.1)$$

⁴⁰ engl. Action

⁴¹ engl. Policy

Π ist die Menge aller möglichen Strategien in einem mehrstufigen Entscheidungsprozess. Die optimale Strategie π^* ist diejenige Strategie, welche die Kostenfunktion für die Zustandsvariablen in Stufe N minimiert und damit die im Vergleich zu den anderen Strategien kleinsten Gesamtkosten aufweist [19].

BELLMAN beschreibt mit den Eigenschaften einer optimalen Strategie das Optimalitätsprinzip:

„An optimal policy has the property that whatever the initial state and initial decision are, the remaining decisions must constitute an optimal policy with regard to the state resulting from the first decision.“ - PRINCIPLE OF OPTIMALITY

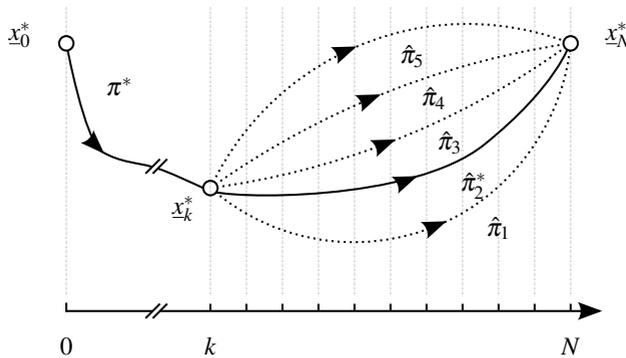


Abb. 5.2.: BELLMANSches Optimalitätsprinzip und die optimale Strategie

Ist die optimale Strategie $\pi^* = \{\mu_0^*, \mu_1^*, \dots, \mu_{N-1}^*\}$ für ein N-stufiges Optimierungsproblem bekannt und betrachtet man das Teilproblem aller möglichen Reststrategien $\hat{\pi}$ vom Zustand x_i^* in Stufe $i = k$ bis zur letzten Stufe N, so ist die optimale Reststrategie $\hat{\pi}^* \{\mu_i^*, \mu_{i+1}^*, \dots, \mu_{N-1}^*\}$, die die Kosten $J_{x_k}^*$ minimiert, identisch der optimalen Gesamtstrategie.

$$J_{x_i}^* = \min_{\pi \in \Pi} \left\{ \sum_{k=i}^{N-1} \xi_k(x_k, \mu(x_k)) + \xi_N(x_N) \right\} \tag{5.2}$$

Die Schrittkosten⁴² $\xi_i(x_k, \mu(x_k))$ bewerten einen Zustandsübergang als Aktion μ in Stufe k. Der letzte Zustand kann getrennt bewertet werden mit $\xi_N(x_N)$. Ein Beweis lässt sich einfach nach FÖLLINGER [56] mit der schematischen Darstellung in Abb. 5.2 formulieren:

⁴² engl. Cost-to-Go

Gibt es eine Reststrategie $\hat{\pi}_1$, die günstiger ist als die optimale Reststrategie $\hat{\pi}_2^*$, dann folgt aus $J(\hat{\pi}_1) < J(\hat{\pi}_2^*)$ dass wegen Additivitätseigenschaften des Gütemaßes auch die Gesamtkosten geringer sein müssen:

$$J(\pi_{0-k}^*) + J(\hat{\pi}_1) < J(\pi_{0-k}^*) + J(\hat{\pi}_2^*) = J(\pi^*) \quad (5.3)$$

Die Voraussetzung, dass $J(\pi^*)$ die Strategie mit den minimalen Kosten darstellt, wird dadurch verletzt. Somit kann die Reststrategie $\hat{\pi}_1$ nicht günstiger sein und $\hat{\pi}_2^*$ ist die optimale Reststrategie. \square

5.1.2. Referenzzyklus

In den folgenden Abschnitten werden verschiedene Varianten der DP vorgestellt, um optimale Strategien unter dem Fokus der Genauigkeit, Rechenzeit und des Speicherbedarfs zu bestimmen. Aus Gründen der Vergleichbarkeit wird in diesem Kapitel bei jeder Methode dasselbe Streckenprofil als Testzyklus verwendet. Der Referenzzyklus ist ein Rundkurs im Großraum Stuttgart, dessen Verteilung der Straßenklassen der Verteilung des deutschen Streckennetzes entspricht (siehe Abschnitt 3.4.2 Deutschland-Runde).

5.2. Diskrete Dynamische Programmierung

Die ursprüngliche Umsetzung der Dynamischen Programmierung erfolgt als Diskrete Dynamische Programmierung (DDP), bei der der Zustandsraum diskret aufgespannt wird. Durch die Mehrstufigkeit entsteht so ein Gitter, an dessen Knoten ein Zustand eindeutig definiert ist. Ein dynamisches System mit kontinuierlichen Zustands- und Steuergrößen muss bei der DDP durch ein diskretes System approximiert werden. Dabei werden Differenzialgleichungen des dynamischen Systems numerisch z. B. durch das explizite EULER-Verfahren interpoliert. Die Zustandsdifferenzialgleichungen (Gl. (5.4)) des dynamischen Systems werden durch die numerische Integration zu Zustandsdifferenzengleichungen (Gl. (5.5)):

$$\dot{\underline{x}}(t) = f(\underline{x}(t), \underline{u}(t), \underline{z}(t), t), \quad x(t_0) = x_0. \quad (5.4)$$

Mit einer zeitdiskreten Abtastung von $\tau = \text{const.}$ folgt:

$$\begin{aligned} \underline{x}_{k+1} &= \underline{x}_k + \tau \cdot f(\underline{x}_k, \underline{u}_k, \underline{z}_k, k), & \tau &= t_{k+1} - t_k \\ &= F(\underline{x}_k, \underline{u}_k, \underline{z}_k, \tau). \end{aligned} \quad (5.5)$$

Da die weitere Betrachtung mit einer konstanten wegdiskreten Abtastung σ fortgesetzt wird, lautet die Zustandsdifferenzengleichung:

$$\underline{x}_{k+1} = F(\underline{x}_k, \underline{u}_k, \underline{z}_k, \sigma), \quad \sigma = s_{k+1} - s_k. \quad (5.6)$$

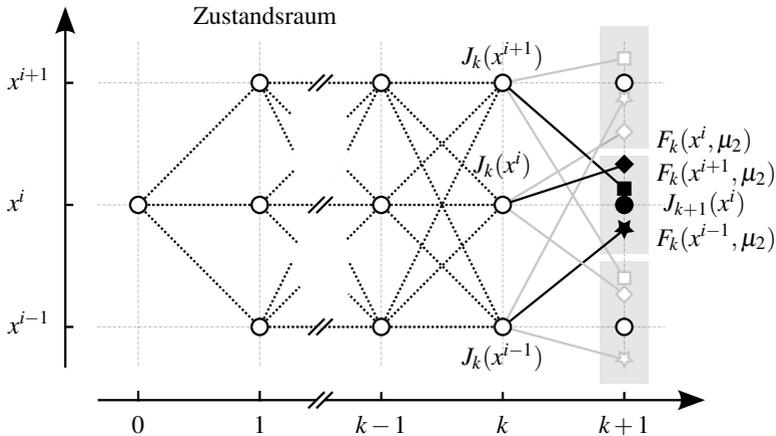


Abb. 5.3.: Berechnung der Schrittkosten in einem diskreten Zustandsnetz bei der DDP

5.2.1. Berechnung der Schrittkosten

In jeder Stufe k werden die Schrittkosten von jedem Zustand x^i im Zustandsraum berechnet. Der Zustandsraum ist diskret abgebildet, die Aktion in einem dynamischen System verläuft kontinuierlich, wodurch der Wert des Folgezustand $F_k(x^i, \mu)$ kontinuierlich berechnet wird und zwischen zwei diskreten Zustandsknoten x_{k+1} liegen kann (siehe Abb. 5.3). Die aufsummierten Schrittkosten $J_k = \sum_0^k \xi_k(x^i, \mu(x^i))$ müssen einem diskreten Zustand x^i zugeordnet werden. Dafür gibt es mehrere Vorgehensweisen [68]:

Nächster Nachbar: Bei der Nächster Nachbar Methode⁴³ werden die Kosten für den Übergang in den benachbarten diskreten Zustand berechnet. In Abb. 5.3 wird die Berechnung aus drei Zuständen exemplarisch gezeigt:

$$J_{k+1}(x^i) = \min_{\mu} \left\{ \begin{array}{l} \xi_k(x^{i+1}, \mu_2) + J_k(x^{i+1}) \\ \xi_k(x^i, \mu_2) + J_k(x^i) \\ \xi_k(x^{i-1}, \mu_2) + J_k(x^{i-1}) \end{array} \right\} \quad (5.7)$$

Diese Methode ist schnell. Bei einem großen Abstand zwischen zwei Zuständen entsteht jedoch ein Rundungsfehler, der Auswirkung auf die Genauigkeit des gesamten Optimierungsergebnisses hat.

Interpolation: Eine weitere Methode der Berechnung von J_k ist die Interpolation. Dabei können unterschiedliche Arten der Interpolation verwendet werden.

⁴³ engl. Nearest Neighbor

Die einfachste und damit auch rechnerisch schnellste Variante ist die lineare Interpolation zwischen zwei benachbarten Zuständen.

$$J_{k+1}(x^i) = \min_{\mu} \left\{ \begin{array}{l} |(F_k(x^{i+1}, \mu_2) - x^i) \cdot \frac{\xi_k(x^{i+1}, \mu_1) - \xi_k(x^{i+1}, \mu_2)}{x^i - x^{i+1}}| + J_k(x^{i+1}) \\ |(F_k(x^i, \mu_2) - x^i) \cdot \frac{\xi_k(x^i, \mu_1) - \xi_k(x^i, \mu_2)}{x^i - x^{i+1}}| + J_k(x^i) \\ |(F_k(x^{i-1}, \mu_2) - x^i) \cdot \frac{\xi_k(x^{i-1}, \mu_2) - \xi_k(x^{i-1}, \mu_3)}{x^{i-1} - x^i}| + J_k(x^{i-1}) \end{array} \right\} \quad (5.8)$$

Die Annahme eines linearen Verhaltens der Kosten zwischen zwei benachbarten Knoten bestärkt die Robustheit der Suche nach einem Minimum bei einer glatten Funktion, kann jedoch fehleranfällig werden, falls die Kostenfunktion durch stark nichtlineares Verhalten charakterisiert ist.

Exakte Kosten

Wie schon bei der Interpolation können einem diskreten Zustand Kosten zugewiesen werden, die durch einen Übergang in einen Zwischenzustand entstehen. Somit können auch die exakten Kosten dem nächsten diskreten Zustand zugewiesen werden. Dabei werden einem Zustand immer die Kosten mit dem minimalen Wert zugewiesen. Der Bereich, in dem Zustände in einem Folgezustand zusammengefasst werden, muss vorgegeben werden. Der Zustandsraum ist durch eine diskrete Anzahl von Zuständen aufgeteilt, deren Wertebereich aber in jeder Stufe neu definiert wird und die damit den Zustandsraum kontinuierlich repräsentieren (siehe Abschnitt 5.4).

Für das Beispiel folgt:

$$J_{k+1}(x^i) = \min_{\mu} \left\{ \begin{array}{l} \xi_k(x^{i+1}, \mu_2) + J_k(F_{k-1}(x^{i+1}, \mu_2)) \\ \xi_k(x^i, \mu_2) + J_k(F_{k-1}(x^i, \mu_2)) \\ \xi_k(x^{i-1}, \mu_2) + J_k(F_{k-1}(x^{i-1}, \mu_2)) \end{array} \right\} \quad (5.9)$$

5.2.2. Diskretisierungseinfluss

Der Abstand zwischen zwei diskreten Zuständen hat bei einem kontinuierlichen dynamischen System einen entscheidenden Einfluss auf die Optimalität des Ergebnisses. Der Optimierer ist gezwungen den nächsten optimalen Zustand zu wählen, obwohl das Gesamtergebnis durch einen Zwischenzustand deutlich besser wäre. Eine möglichst kleine Diskretisierung garantiert ein optimales Ergebnis, ist jedoch durch eine lange Rechenzeit und einen hohen Speicherbedarf charakterisiert. In Abb. 5.4 wurde die Anzahl der Zustände für die Optimierung der Geschwindigkeit auf dem Referenzzyklus dargestellt. Zur Bewertung einer optimalen Strategie werden die Gesamtkosten J^* herangezogen⁴⁴.

⁴⁴ Dieser Wert wird in der Literatur auch als Performance Index bezeichnet [115]

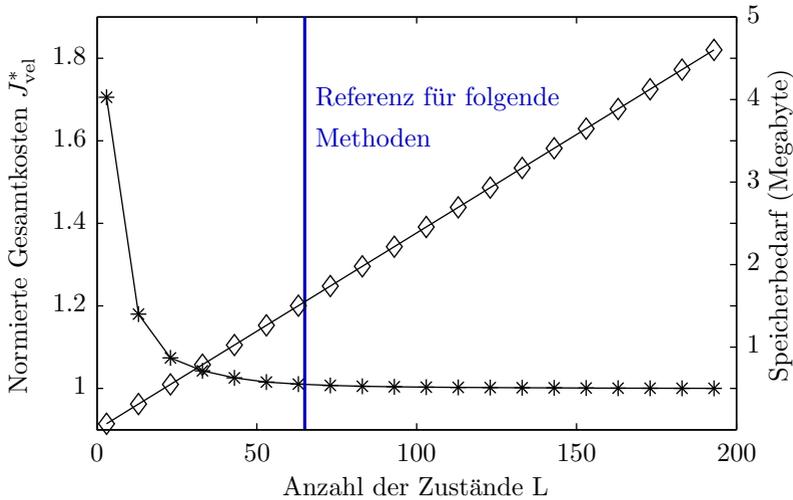


Abb. 5.4.: Normierte Gesamtkosten optimaler Strategien über der Anzahl von Zuständen zur Definition eines optimalen Ergebnisses als Vergleichswert für das Referenzbeispiel

Als Referenz für folgende Methoden wird eine Diskretisierung gewählt, die als Gesamtkosten eine 1 % Abweichung von der betrachteten maximalen Diskretisierung aufweist. Die Anzahl der Zustände sind $L_{ref} = 65$, bei einem benötigten Speicher von 1,55 Megabytes.

5.2.3. Fluch der Dimensionen

BELLMAN beschreibt schon in seinen ersten Ausführungen [19] [145] die möglichen Probleme bei der praktischen Umsetzung der DP und spricht vom „Fluch der Dimensionen“⁴⁵. LUUS bezeichnet es als die „Plage des wachsenden Netzes“⁴⁶ [115].

POWELL konkretisiert drei „Flüche der Dimensionen“ [135]:

- Der Zustandsraum \mathcal{X} : Die Zustandsvariable \underline{x} kann I Dimensionen annehmen. Jede Dimension ist durch $L - 1$ Intervalle aufgespannt, so ergeben sich L^I unterschiedliche Zustände und damit auch die gleiche Anzahl an möglichen optimalen Strategien in N .
- Der Aktionsraum \mathcal{A} : Der Steuervektor \underline{u} kann K Dimensionen annehmen, wobei der Vektor durch P Werte definiert ist, so ergeben sich P^K unterschiedliche Aktionen

⁴⁵ engl. Curse of Dimensionality

⁴⁶ engl. Menace of the Expanding Grid

- c.) Der Wahrscheinlichkeitsraum \mathcal{W} : Stochastische dynamische Prozesse werden durch Zufallsvariablen \underline{w} beschrieben, die durch M Werte definiert sind und J Dimensionen haben. So entstehen M^J Möglichkeiten.

Da in dieser Arbeit deterministische Systeme betrachtet werden, beschränkt sich die Komplexitätsbetrachtung auf den Zustands- und Aktionsraum.

Betrachtet man die Komplexität der DDP aus Sicht der Rechenzeit so ergibt sich bei N Stufen:

$$\mathcal{O}(N \cdot L^J \cdot P^K). \quad (5.10)$$

Wird die Nächster Nachbar Methode verwendet, entspricht die Anzahl der Aktionen der aller Folgezustände. Im schlechtesten Fall werden alle Übergänge aus jedem aktuellen diskreten Zustand zu allen Folgezuständen überprüft. Dies erfolgt alle Distanzstufen N , wodurch sich folgende Komplexität ergibt:

$$\mathcal{O}(N \cdot L^J \cdot L^J) = \mathcal{O}(N \cdot (L^J)^2). \quad (5.11)$$

In der Regel werden zu jeder Distanzstufe die Kosten des Zustands und der Vorgängerzustand zur Rückverfolgung der Aktionen abgespeichert, sodass diese zwei Werte für jeden betrachteten Zustand gespeichert werden müssen. Die Komplexität des Rechenspeichers ist dadurch wie folgt definiert:

$$\mathcal{O}(N \cdot 2 \cdot L^J). \quad (5.12)$$

Der exponentielle Einfluss der Dimensionen auf die Rechenzeit und den Speicher hat zur Folge, dass die DDP größtenteils für Probleme mit niedriger Systemordnung angewendet oder auf solche reduziert wird. Durch die Einschränkung des Suchraums der Optimierung auf relevante Bereiche wird die Rechenzeit reduziert.

5.2.4. Reduktion des Suchraums

Der Suchraum ist bei deterministischen Systemen durch den Zustandsraum \mathcal{X} und den Aktionsraum \mathcal{A} aufgespannt. Mit der DP sind von jedem Zustand $x_k \in \mathcal{X}_k$ in jeder Stufe k optimale Strategien vorhanden. In jeder Stufe k kann der Suchraum angepasst werden:

$$\mathcal{X}_k \in \mathcal{X} \quad \text{und} \quad \mathcal{A}_k \in \mathcal{A} \quad (5.13)$$

In den meisten Fällen ist der Anfangszustand⁴⁷ $\underline{x}_0 \in \mathcal{X}_0^A$ vorgegeben. Der Aktionsraum \mathcal{A}_k definiert, welcher Folgezustandsraum \mathcal{X}_{k+1} aus dem aktuellen Zustandsraum überhaupt erreichbar ist. Dabei kann dieser Aktionsraum wiederum abhängig vom aktuellen Zustandsraum sein.

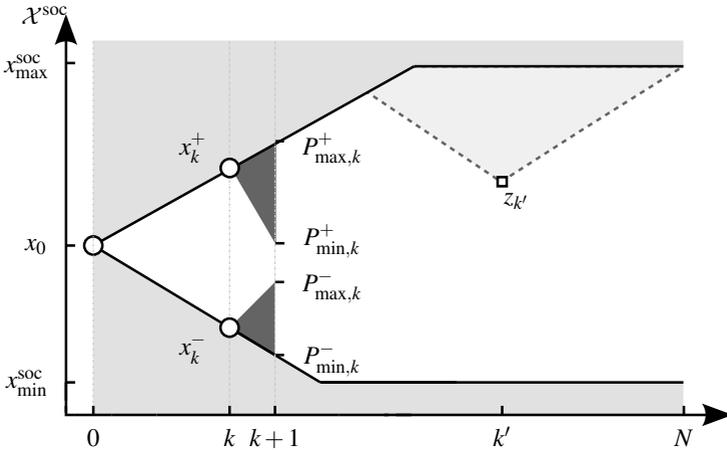


Abb. 5.5.: Reduzierter Zustandsraum der Batterie

Zustandsraum der Batterie: Betrachtet man den aktuellen Zustand der Batterie x_k^{soc} , so wird der Folgezustand wie folgt berechnet:

$$x_{k+1}^{\text{soc}} = x_k^{\text{soc}} + P_k(x_k^{\text{soc}}) \cdot \Delta t_k \quad (5.14)$$

Der Zustandsraum wird, wie in Abb. 5.5 dargestellt, global durch eine minimal und maximal erlaubte Batterieladung begrenzt um die Batterie nicht nachhaltig zu beschädigen.

$$\mathcal{X}_k^{\text{soc}} = \{x_k^{\text{soc}} \mid x_{\min}^{\text{soc}}(k) \leq x_k^{\text{soc}} \leq x_{\max}^{\text{soc}}(k); k = 0, \dots, N\} \quad (5.15)$$

Die geforderte Leistung $P(x_k^{\text{soc}})$ begrenzt den Aktionsraum, da durch die physikalischen Eigenschaften der Komponenten weitere Randbedingungen entstehen. Diese Randbedingungen sind nicht nur von der aktuellen Stufe, sondern auch vom aktuellen Zustand abhängig, der z. B. Auswirkungen auf Wirkungsgrade der Komponenten mit sich bringt und damit die Leistung erneut einschränkt.

$$\mathcal{A}_k^{\text{soc}} = \{P(x_k^{\text{soc}}) \mid P_{\min}^{\text{soc}}(x_k^{\text{soc}}, k) \leq P(x_k^{\text{soc}}) \leq P_{\max}^{\text{soc}}(x_k^{\text{soc}}, k); k = 0, \dots, N\} \quad (5.16)$$

Zusätzlich zu den Anfangs- und Endbedingungen kann auch eine ortsabhängige Vorgabe als weitere Randbedingung $z_{k'}$ den Zustandsraum reduzieren, indem Bereiche, die nicht erreicht werden sollen, vom Suchraum ausgeschlossen werden.

Unterscheidet man diskrete Hybridmodi, so wird der Aktionsraum $\mathcal{A}_k^{\text{soc,h}}$ weiter eingeschränkt. Dies hat wiederum Auswirkungen auf die Leistung.

⁴⁷ Der Anfangszustandsraum $\mathcal{X}_0^A = \underline{x}_0$ schrumpft auf eine Punktmenge zusammen [12]

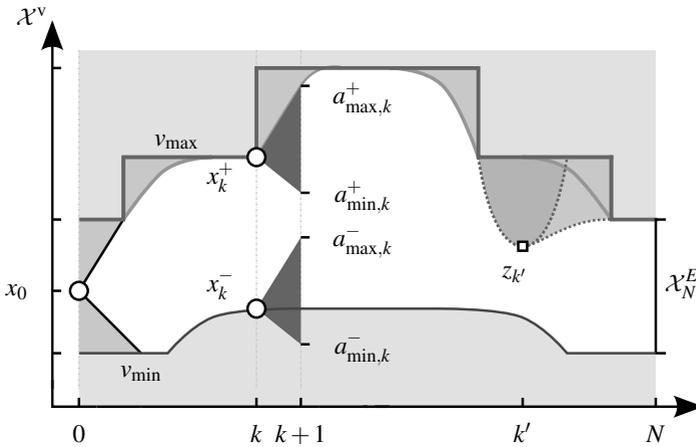


Abb. 5.6.: Reduzierter Zustandsraum der Geschwindigkeit

Nicht in jedem Hybridmodus kann die gesamte Leistungsbandbreite verwendet werden. Diese ist abhängig vom jeweiligen Zustand. Bei rein elektrischer Fahrt ist z. B. je nach angeforderter Zugkraft die benötigte Batterieladung durch einen Zustandsübergang vorgegeben, während bei einer Unterstützung des Verbrennungsmotors mehr Zustandsübergänge möglich sind.

Zustandsraum der Geschwindigkeit: Eine für die Fahrstrategie relevante Zustandsvariable ist die Geschwindigkeit. Dabei können sowohl interne als auch externe Randbedingungen auftreten, die den Zustandsraum einschränken. Zu den internen Randbedingungen zählen die physikalischen Eigenschaften des Fahrzeugs, die z. B. maximale und minimale Längsbeschleunigungen festlegen.

$$x_{k+1}^v = x_k^v + a_k(x_k^v) \cdot \Delta t_k \quad (5.17)$$

Externe Randbedingungen sind vom Fahrzeug unabhängig und können z. B. ein gewünschtes Beschleunigungs- und Verzögerungsverhalten darstellen sowie durch eine maximale Geschwindigkeit v_{\max} und eine minimale Geschwindigkeit v_{\min} gekennzeichnet sein. Der Zustandsraum \mathcal{X}^v lässt sich mit den externen Randbedingungen auf ein Band reduzieren, den sogenannten Fahrtschlauch [138]. Die obere Geschwindigkeitsgrenze wird meist durch die gesetzlich erlaubte Höchstgeschwindigkeit vorgegeben, kann aber auch durch Verkehrseinfluss nochmals reduziert werden. Die untere Geschwindigkeitsgrenze dient einem Ausschließen von Zuständen, die bei einer Bewertung durch die Fahrzeit weniger wahrscheinlich bis gar nicht relevant sind (siehe Abb. 5.6). Diese untere Grenze ist eine weiche Randbedingung und dient dazu, Rechenzeit und benötigten Speicher zu reduzieren.

5.2.5. Kostenfunktion

Bei der praktischen Umsetzung der DDP wird die Kostenfunktion in Form einer $L^I \times N$ Kostenmatrix J^M umgesetzt, wobei L^I die diskreten Zustände über der Dimension I darstellen und N die Anzahl der endlichen Stufen.

In Abb. 5.7 ist die Kostenmatrix für je einen eindimensionalen Entscheidungsprozess zur Suche nach der optimalen Geschwindigkeit und der optimalen Batterieladungsstrategie für den Referenzzyklus dargestellt. Der streng monoton steigende Anstieg über der Distanz ist in beiden Optimierungsproblemen charakteristisch für die Kostenfunktion, da in jeder Stufe die Schrittkosten zu den bisherigen Kosten aufaddiert werden.

Die Einschränkungen des Suchraums in Form eines Fahrschlauchs sind bei der Geschwindigkeitsstrategie (Abb. 5.7 oben) deutlich zu erkennen. Die Kostenfunktion ist im aufgespannten Zustandsraum definiert. Bei der Kostenfunktion der Batterieladungsstrategie (Abb. 5.7 unten) ist der Anfangszustand x_0^{soc} mit der maximal erlaubten Batterieladung identisch, wodurch der Suchraum lediglich durch die maximal mögliche Entladung über die ersten 30 km von diesem Anfangszustand eingeschränkt wird. Dies entspricht dem Wert der rein elektrischen Reichweite (AER) des Versuchsfahrzeugs.

Das Erstellen der Kostenfunktion ist der Kern jeder DP und bestimmt Genauigkeit, Rechenzeit und Speicheranforderungen der Berechnung einer optimalen Strategie. Alle folgenden Methoden befassen sich deshalb mit dem Thema, wie die Kostenfunktion möglichst genau, schnell und mit wenig Speicher aufgebaut werden kann.

5.2.6. Vorwärts- und Rückwärtsrechnung

Zur Berechnung der DDP sind zwei Rechenschritte notwendig. Im ersten Rechenschritt wird die Kostenfunktion berechnet. Im Zweiten wird von einem gewünschten Zustand aus die Strategie zurückgerechnet. Neben der Kostenmatrix ist eine Pfadmatrix notwendig, in der für jeden Wert der Kostenmatrix der Vorgängerzustand gespeichert ist. Das Zurückrechnen der Strategie aus der Kostenmatrix über die Pfadmatrix kann deshalb auch als Pfadrückverfolgung bezeichnet werden.

Die Berechnung entlang der Distanzstufen wird als Vorwärtsrechnung bezeichnet. Die Pfadrückverfolgung, die in Stufe $k = N$ startet, wird in der Literatur auch als Rückwärtsrechnung bezeichnet [135, 23]. Je nach Aufgabenstellung wird die Kostenfunktion in einer Vorwärts- oder einer Rückwärtsrechnung berechnet. Alle in dieser Arbeit verwendeten Methoden berechnen die Kostenfunktion in der Vorwärtsrechnung.

In Algorithmus 1 ist die Vorwärtsrechnung zur Erstellung der Kostenfunktion über einen endlichen Horizont dargestellt.

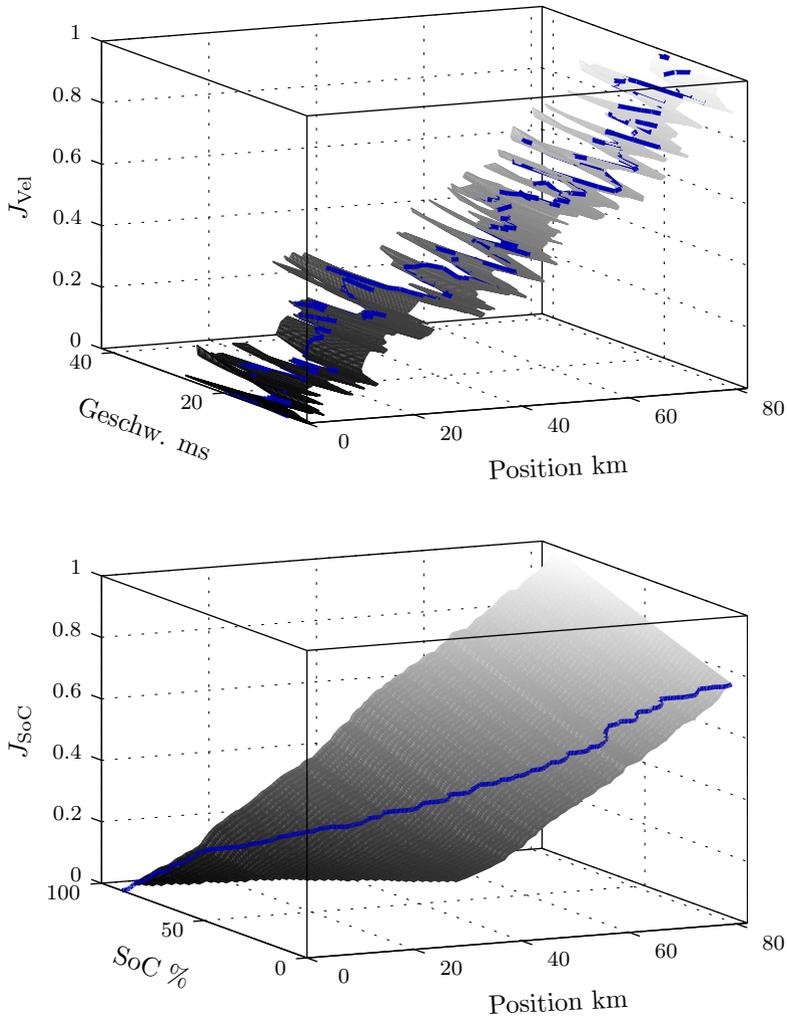


Abb. 5.7.: Kostenfunktionen in Matrixform für eine Geschwindigkeits- und Batterieladungsstrategie. Die optimalen Strategien sind in blau eingezeichnet

Algorithmus 1 : Vorwärtsrechnung zur Erstellung der Kostenfunktion (DDP)

Input : Anfangszustand x_0
Output : Kostenfunktion J
begin

$J_0(x_0) := 0 \quad \forall x_0 \in \mathcal{X}_0 \quad // \text{Initialisiere Anfangszustand } x_0$

for $k = 0 : N - 1$ **do**

$J_{k+1}(x_k) := \min_{\mu_k} \left\{ \xi_k(x_k, \mu(x_k)) + J_k(x') \right\} \Big|_{x_k \in \mathcal{X}_{k+1}, x' \in \mathcal{X}_k}$

5.2.7. Prädiktionshorizont

Die Kostenfunktion liefert zu jeder Stufe k die optimalen Kosten bis zu dieser Stufe und somit am Horizontende N die aufsummierten optimalen Kosten über den betrachteten Horizont. Die Wahl des Horizonts hat dadurch einen entscheidenden Einfluss auf das Ergebnis, denn es können nur Einflüsse auf die Optimierung in Betracht gezogen werden, die innerhalb des Horizonts liegen.

Endet zum Beispiel der Optimierungshorizont kurz vor einer Verzögerungsphase wie in Abb. 5.8 bei 3,25 km gezeigt, ist bei Auswahl einer hohen Geschwindigkeit (Kreis) eine folgende Verzögerung nicht mehr realisierbar.

Ein Ausschnitt der ersten 8 km auf dem Referenzzyklus zeigt in Abb. 5.8, wie sich optimale Strategien am Ende verschiedener betrachteter Horizonte für alle Zustände an diesem Ende verhalten. Dazu wird die Optimierung nach je 850 m abgebrochen und optimale Strategien ermittelt. Die Position, bei der alle Strategien für einen betrachteten Horizont N_i in einem gemeinsamen Punkt enden, variieren dabei stark je nach Fahrsituation. Für den Referenzzyklus liegt dieser Punkt im Durchschnitt 500 m vor N_i , kann aber gerade bei höheren Geschwindigkeiten bis zu 3,1 km zurückliegen⁴⁸. Diese Mindestlänge eines Prädiktionshorizonts für Geschwindigkeitsstrategien kann auf längeren Autobahnabschnitten durchaus 20 km überschreiten und hängt bei Energiemanagementstrategien von der Größe der Batterie und der installierten elektrischen Leistung ab [184].

⁴⁸ Dieser Punkt liegt außerhalb des in Abb. 5.8 gezeigten Ausschnittes

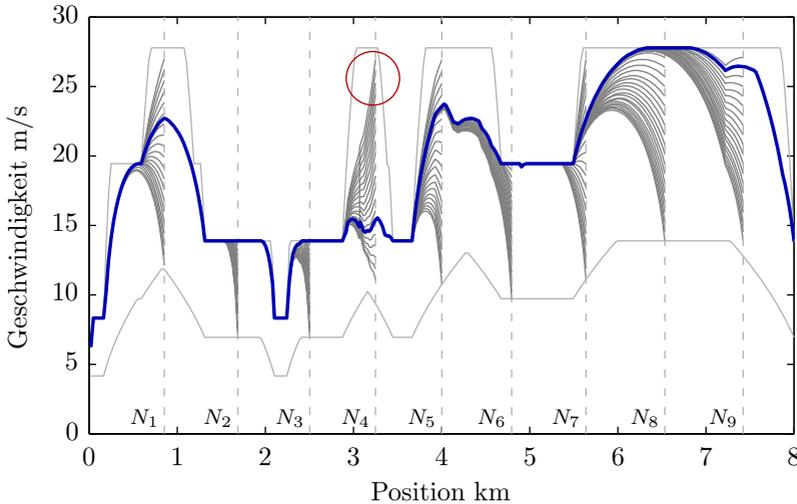


Abb. 5.8.: Auswirkung der Länge des Prädiktionshorizonts auf die optimale Strategie für alle möglichen Zustände am Ende eines Horizonts N_i .

5.3. Iterative Dynamische Programmierung

Die DP ist definiert durch das Aufteilen eines komplexen Gesamtproblems in einfachere Teilprobleme. Das Aufteilen in Stufen kann auch als Iterationsmethode verstanden werden und wurde von BELLMAN in seiner ersten Arbeit [19] unter dem Begriff *Successive approximations* ausgiebig untersucht. Die DDP kann deshalb auch als *Iteration der Kosten*⁴⁹ über N Stufen bezeichnet werden [135].

Eine schrittweise (sukzessive) Suche nach dem Optimum beinhaltet ein iteratives Vorgehen, welches auf unterschiedliche Weise realisiert werden kann.

Im Folgenden werden verschiedene Formen der Iteration vorgestellt, die aus anderen Fachbereichen bekannt sind und deren Idee auf die vorliegende Aufgabenstellung angepasst wurde.

5.3.1. Iteration der Strategien

Bei der *Iteration der Strategien*⁵⁰ wird die Kostenmatrix nicht in einem Durchlauf über N Schritte, sondern iterativ um eine vorhandene suboptimale Strategie aufgebaut. Ausgehend von einer initialen Strategie wird in jeder Iteration eine Verbesserung der Strategie angestrebt.

⁴⁹ engl. Value Iteration

⁵⁰ engl. Policy Iteration

Der Algorithmus ist in zwei Phasen aufgeteilt, der Strategiebewertung (Policy Evaluation) und der Strategieverbesserung (Policy Improvement). Algorithmus 2 beschreibt eine auf das vorliegende Optimierungsproblem angepasste Form der Policy Iteration.

Algorithmus 2 : Iteration der Strategien für einen endlichen Horizont (IDP1)

Input : Initiale Strategie π_0 wird vorgegeben,
Suchweite ρ wird festgelegt

Output : Kostenfunktion J

begin

$J(x_k) := \infty \quad \forall x_k \in \mathcal{X}, k = 0, 1, \dots, N$

$l := 0$

while $\pi_{l+1} \neq \pi_l$ **do**

$\mathcal{X}^{\pi_l} \subseteq \left[x^{\pi_l} - \frac{\rho}{2}, x^{\pi_l} + \frac{\rho}{2} \right]$

// Strategiebewertung (Policy Evaluation):

for $k = 0 : N - 1$ **do**

$$J_{k+1}^{\pi_l}(x_k) := \xi_k(x_k, \mu(x_k)) + J_k(x') \Big|_{x_k \in \mathcal{X}_{k+1}^{\pi_l}, x' \in \mathcal{X}_k^{\pi_l}}$$

// Strategieverbesserung (Policy Improvement):

$$\pi_{l+1} := \arg \min_{\mu} \{J_N(x, \mu(x))\}$$

$l := l + 1$

In der Strategiebewertung werden um eine bestehende Strategie im Suchraum \mathcal{X}^{π_l} die Kosten in jeder Stufe k berechnet und in die Werte in die Kostenmatrix J eingetragen. In der Strategieverbesserung wird die Strategie mit den besten Kosten in N ausgewählt. Um diese neue kostengünstigere Strategie werden in einer weiteren Iteration Kosten berechnet. Dabei wird die Kostenmatrix in den Bereichen befüllt, in denen eine Strategie betrachtet wurde. Ein Abbruch erfolgt, wenn die Strategien zweier aufeinander folgenden Iterationen identisch sind⁵¹. Die Wahl der initialen Strategie sowie des Suchraums \mathcal{X}^{π_0} um eine Strategie hat einen entscheidenden Einfluss auf die Anzahl der Iterationen.

⁵¹ Bei konvexen Optimierungsproblemen kann von einem globalen Optimum ausgegangen werden. Bei nicht konvexer Kostenfunktion kann diese Lösung auch eine lokal optimale Lösung darstellen, solange nicht der ganze Zustandsraum abgesucht wurde.

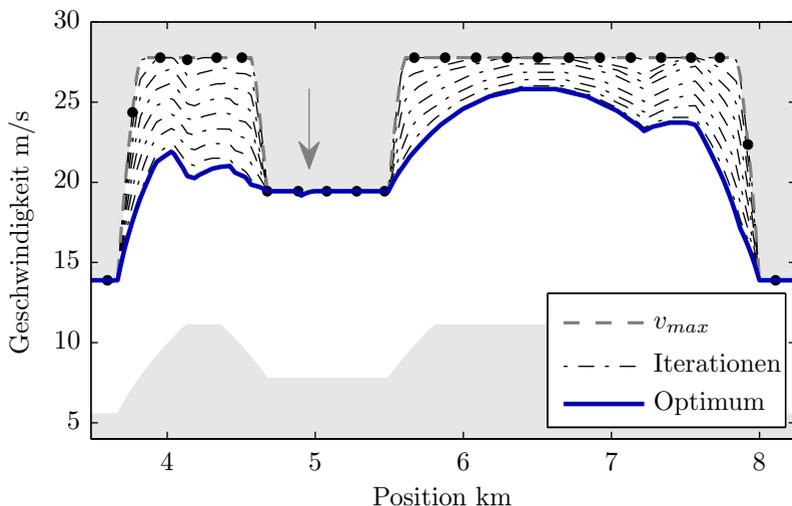


Abb. 5.9.: Anwendung der Policy Iteration auf die optimale Geschwindigkeitsstrategie als Ausschnitt aus der Beispielstrecke

Eine ungünstig gewählte initiale Strategie kann dazu führen, dass der gesamte Optimierungsraum durchsucht werden muss, bevor die Lösung gefunden werden kann. Die Anzahl der Zustände ρ um die betrachtete Strategie π_l definiert den Suchraum und legt fest, welcher Bereich in jeder Iteration untersucht wird. Dieser muss nicht konstant definiert sein, sondern kann je nach Erkundungsrate in jeder Iteration und Stufe angepasst werden.

Die Erkundungsrate für eine Stufe ist z. B. hoch, solange die neue Strategie durch einen Randzustand $x^{\pi_l} - \frac{\rho}{2}$ oder $x^{\pi_l} + \frac{\rho}{2}$ verläuft und niedrig, wenn sich der optimale Zustand von einer Strategie zur nächsten nicht ändert. Dies lässt sich durch einen Zustandszähler realisieren, der aufsummiert, wie oft ein Zustand über die Iterationen für optimal befunden wurde.

In Abb. 5.9 wird eine optimale Geschwindigkeitsstrategie mit der Policy Iteration berechnet. Dabei wird als initiale Strategie π_0 die obere Begrenzung des Zustandsraums v_{\max} gewählt. In jeder Iteration sinken die Strategien ab, bis das Optimum erreicht ist.

Iteration der Strategien mit initialer Strategiesuche

Da sich die Wahl der initialen Strategie π_0 entscheidend auf die Zeit bis zur Konvergenz bei der Policy Iteration auswirkt, liegt eine initiale Strategiesuche nahe.

Dabei bietet sich die DDP mit einem sehr grob diskretisierten Zustandsraum \mathcal{X}_R an. Man spricht dabei von einer hybriden Iteration der Werte und der Strategien⁵² [135].

5.3.2. Iterative Änderung des Zustandsraums

Neben der iterativen Suche in einem fixen diskretisierten Zustandsraum, beschreibt BELLMAN in [145] die Methode der iterativen Gitterverfeinerung. Die Idee wurde von weiteren Arbeiten aufgegriffen und weiterentwickelt [45] [124] [73].

LUUS wendet diese Methode der Iterativen Dynamischen Programmierung (IDP) als Erster auf die Optimierung eines mehrdimensionalen Steuerverlaufs unter anderem in einem chemischen Reaktionsverfahren an [113] [112]. Die Lösung der Optimierung in einem 250-dimensionalen Steuerraum mit der IDP wird in [114] vorgestellt.

In der IDP wird die klassische Dynamische Programmierung nacheinander mehrfach durchgeführt, während der Zustandsraum, repräsentiert als ein Gitter, immer feiner um gefundene Strategien gewählt wird. In der ersten Iteration wird die optimale Strategie in einem groben Zustands- und Steuergitter berechnet. Die optimale Strategie aus der ersten Iteration wird als Mittelpunkt für das Aufspannen des Zustandsgitters in der nächsten Iteration benutzt. Die Größe des Gitters wird in jeder Iteration reduziert, während die Anzahl der Gitterpunkte konstant bleiben, sodass die Intervalle zwischen den Gitterpunkten schrumpfen und die optimale Strategie in jeder Iteration genauer angenähert wird. Basierend auf [182] und [113] wird der Ablauf der Optimierung in Algorithmus 3 beschrieben.

In Abb. 5.10 ist ein Ausschnitt des Geschwindigkeitszustandsraums zu sehen, der durch eine obere (v_{\max}) und untere Geschwindigkeitsbegrenzung (v_{\min}) aufgespannt ist. Der Zustandsraum ist in diesem Beispiel mit $L = 3$ Gitterpunkten unterteilt, sodass in der ersten Iteration Zustände an den Grenzen und in der Mitte möglich sind. Der Suchraum r spannt somit den kompletten Bereich zwischen oberer und unterer Begrenzung auf. Nach der ersten Iteration liegt eine optimale⁵³ Strategie vor, die als Mittelpunkt für den neuen Suchraum dient. Dieser wird wiederum um den Reduktionsfaktor γ für die nächste Iteration verkleinert:

$$v_{\max,k}^{l+1} = v_k^{*l} + 0,5 \cdot \gamma \cdot (v_{\max,k}^l - v_{\min,k}^l) \quad (5.18)$$

$$v_{\min,k}^{l+1} = v_k^{*l} - 0,5 \cdot \gamma \cdot (v_{\max,k}^l - v_{\min,k}^l) \quad (5.19)$$

Der Zustandsraum wird so in jeder Iteration an einen Suchraum um eine optimale Strategie angepasst. Der Speicherbedarf kann durch eine feste Anzahl an Gitterpunkten reduziert werden. Die global optimale Strategie wird iterativ bestimmt.

⁵² engl. Hybrid Value-Policy Iteration

⁵³ Optimal bezieht sich auf den jeweils gewählten Zustandsraum

Algorithmus 3 : Iterative Änderung des Zustandsraums (IDP2)**Input** : Grenzen des Zustandsraums x_{\min}, x_{\max} ,Anzahl der Zustände als Gitterpunkte L im Zustandsraum \mathcal{X}_l ,Reduktionsfaktor γ **Output** : Kostenfunktion J **begin** $l := 0$

// Initialer Zustandsraum:

$$\mathcal{X}_l := \{\underline{x}^l, | x_{\min}^l(k) \leq x_k^l \leq x_{\max}^l(k); k = 0, \dots, N\}$$

while $J_{l+1}^* \neq J_l^*$ **do**

$$\hat{J}^{L \times N}(x) := \infty \quad \forall x_k \in \mathcal{X}_l, k = 0, 1, \dots, N$$

for $k = 0 : N - 1$ **do**

$$\hat{J}_{k+1}(x_k) := \min_{\mu_k} \{ \xi_k(x_k, \mu(x_k)) + \hat{J}_k(x') \} \Big|_{x_k \in \mathcal{X}_{k+1}, x' \in \mathcal{X}_k}$$

$$J_{l+1}^* := \min \{ \hat{J}_N \}$$

$$r_{l+1} := \gamma \cdot r_l \quad // \text{Suchregion wird verkleinert}$$

// Anpassung der Grenzen um optimale Zustandsfolge \underline{x}^* :

$$\underline{x}_{\min}^{l+1} := \underline{x}^* - \frac{r_{l+1}}{2}$$

$$\underline{x}_{\max}^{l+1} := \underline{x}^* + \frac{r_{l+1}}{2}$$

// Anpassung Zustandsraum:

$$\mathcal{X}_{l+1} := \{\underline{x}^{l+1}, | x_{\min}^{l+1}(k) \leq x_k^{l+1} \leq x_{\max}^{l+1}(k); k = 0, \dots, N\}$$

 $l := l + 1$

Bei der IDP tragen der Reduktionsfaktor γ und die Anzahl der Zustände L entscheidend zu einer schnellen Lösung mit wenig Iterationen bei. Der Einfluss dieser Faktoren wird nacheinander für die Optimierung der Geschwindigkeitsstrategie im Referenzzyklus gezeigt.

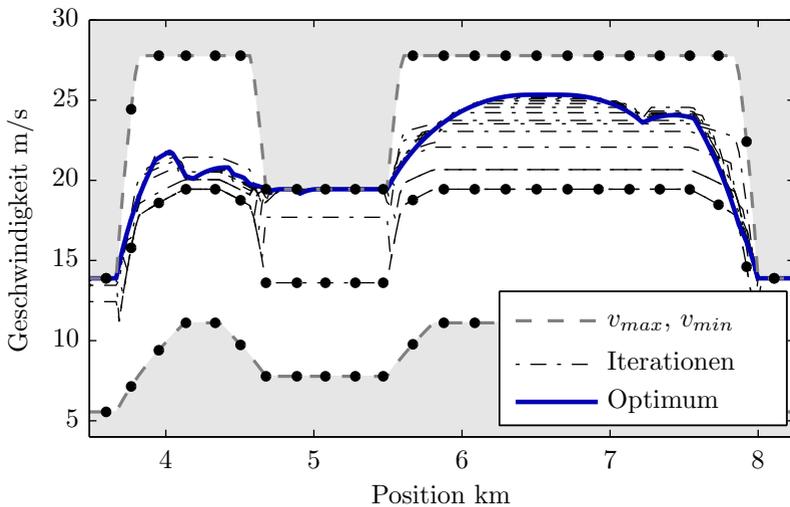


Abb. 5.10.: Anwendung der IDP auf die optimale Geschwindigkeitsstrategie als Ausschnitt aus der Beispielstrecke

Mit $L = 3$ Zuständen wird γ in Abb. 5.11 über die Anzahl der Iterationen variiert. Dargestellt sind die optimalen Gesamtkosten \hat{J}_{vel}^* normiert auf die Vergleichskosten der DDP-Lösung.

Der Wert eins bedeutet eine identische optimale Strategie zwischen der DDP und der IDP Variante. Betrachtet man eine tolerierte Abweichung von 1 % (rot), verbessern sich die Ergebnisse bei Reduktionsfaktoren $\gamma < 0,7$ und zunehmenden Iterationen nicht. Wie auch in [182] beobachtet, wird der Suchraum zu schnell eingeschränkt, sodass über mehrere Iterationen die Strategien in einem lokalen Minimum hängen bleiben. Dieser Effekt tritt bei jeder Genauigkeitsstufe auf. Für jede tolerierte Abweichung vom Optimum lässt sich so ein Pareto optimaler Punkt bestimmen, bei dem mit möglichst wenigen Iterationen die optimale Strategie erreicht wird. Die identische Strategie $\hat{J}_{\text{vel}}^* = 1$ wird in 42 Iterationen und einem Reduktionsfaktor $\gamma = 0,87$ erreicht⁵⁴.

In Abb. 5.12 wurde bei einem festen Reduktionsfaktor von $\gamma = 0,75$ die Anzahl der Zustände über der Anzahl der Iterationen variiert. Die Höhenlinien stellen die Gesamtkosten J_{IDP}^* normiert auf die Kosten der Referenz J_{DDP}^* dar. Für identische Ergebnisse sind mindestens 5 Zustände notwendig. Wobei für eine erlaubte Abweichung von 1 % nur 3 Zustände bei 19 Iterationen ausreichen (rot). Die Auswahl der optimalen Punkte auf einer Paretofront mit gleich großer Genauigkeit erfolgt über die Berechnungszeit.

⁵⁴ LUUS schlägt einen idealen Reduktionsfaktor von 90 % für die untersuchten Optimierungsprobleme in der Verfahrenstechnik vor [115].

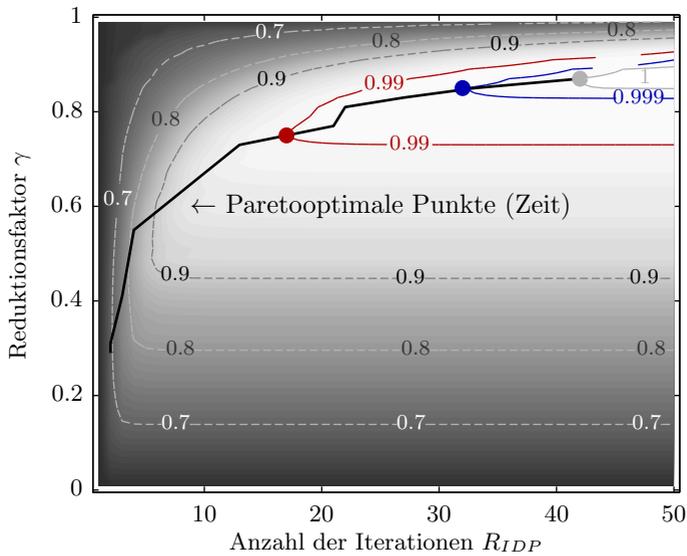


Abb. 5.11.: Gesamtkosten J_{IDP}^* normiert auf die DDP Methode als Variation des Reduktionsfaktors γ über 50 Iterationen für den Referenzzyklus

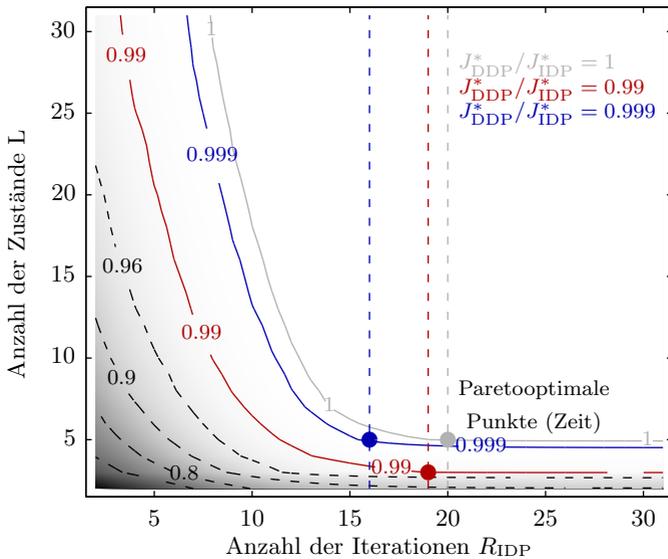


Abb. 5.12.: Gesamtkosten J_{IDP}^* normiert auf die DDP Methode als Variation der Zustände L über 30 Iterationen auf dem Referenzzyklus

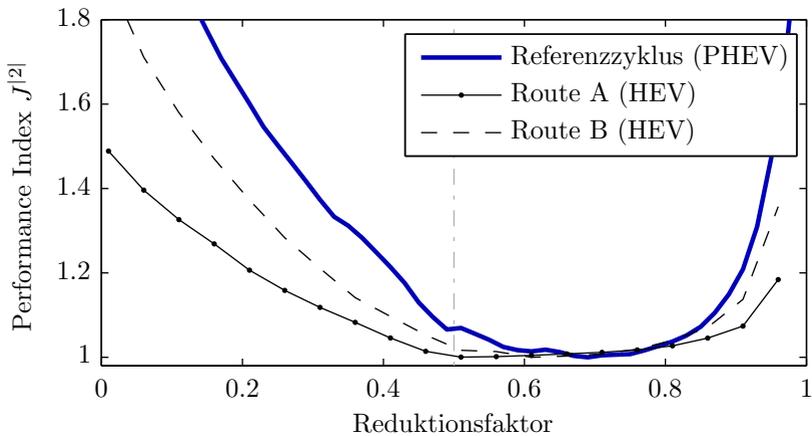


Abb. 5.13.: Performance Index $J^{|2|}$ über Reduktionsfaktor γ für verschiedene Routen mit unterschiedlicher Streckencharakteristik, -länge und Fahrzeugeigenschaften [182]

Die Optimalität der Parameter ist abhängig von den Streckeneigenschaften einer Route. Für einen Vergleich wird die Quadratsumme der optimalen Gesamtkosten $J^{|2|}(\gamma)$ bestimmt:

$$J^{|2|}(\gamma) = \left(\frac{\sum_l J_{\text{vel}}^*(\gamma, l)}{\min_{\gamma} (\sum_l J_{\text{vel}}^*(\gamma, l))} \right)^2 \quad (5.20)$$

In Abb. 5.13 ist $J^{|2|}(\gamma)$ über 50 Iterationen für den Referenzzyklus und zwei weiteren Routen aus [182] aufgetragen, die mit kleinerer Batterie und installierter elektrischer Leistung berechnet wurden. Bei unterschiedlicher Streckenlänge und Streckencharakteristik sowie Fahrzeugeigenschaften (Größe der Batterie und E-Maschine) ist ein Bereich für einen optimalen Reduktionsfaktor $0,5 \leq \gamma < 1$ definierbar.

5.3.3. Vergleich: DDP versus IDP

Ein Vergleich der Berechnung zwischen der DDP und der IDP für den Referenzzyklus auf derselben Rechenmaschine⁵⁵ verdeutlicht das Potenzial iterativer Optimierung. Die optimale Strategie mittels DDP und 200 Zuständen stellt die Referenzstrategie dar. Wie in Tabelle 5.1 dargestellt, wird der Vergleich anhand der Abweichung der Kostenfunktionen sowie des benötigten Speichers und der Rechenzeit durchgeführt. Die Anzahl der Zustände und die damit verbundene Speicherkapazität kann bei identischen Gesamtkosten J^* von 200 auf 5 Zustände reduziert werden (7,69 %).

⁵⁵ PC mit 2,5 GHz Prozessor (1534 DMIPS im nicht optimierten Dhrystone Benchmark Test)

Tab. 5.1.: Vergleich der DDP und der IDP Methode

	DDP			IDP		
	100	99,9	99	100	99,9	99
Genauigkeit (%)	100	99,9	99	100	99,9	99
Rechenzeit (%)	100	55,78	10,98	16,04	13,91	9,56
Speicher (%)	100	75	32,5	7,69	7,69	4,62
Anzahl Zustände (-)	200	150	65	5	5	3
Anzahl Iterationen (-)	1	1	1	20	16	19

Identische Gesamtkosten sind durch eine Genauigkeit von 100 % dargestellt. Durch eine Reduktion der Genauigkeit, verbunden mit höheren Gesamtkosten, kann die Rechenzeit von 16,04 % auf 9,56 % weiter gesenkt werden.

In Abb. 5.14 sind die Geschwindigkeitsstrategien sowie deren Residuen bei zwei unterschiedlichen Genauigkeitsstufen aufgetragen. Während bei identischen Gesamtkosten eine Abweichung von maximal 1 m/s auftritt, entstehen bei einer Genauigkeit der Kosten von 99 % Abweichungen bis zu 5 m/s (siehe Abb. 5.14 bei Position 30 km). Je nach Anforderung an Genauigkeit, Rechenzeit und Speicher kann die Optimierung ausgelegt werden.

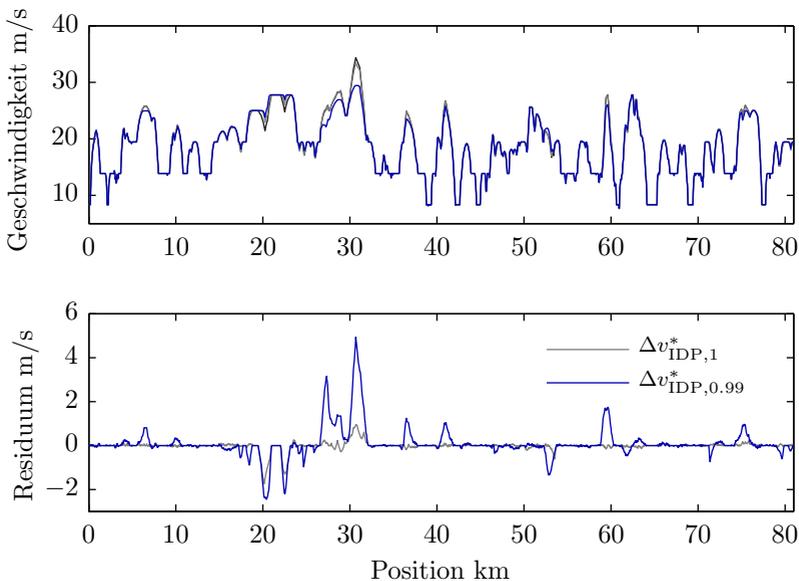


Abb. 5.14.: Geschwindigkeitsstrategien mit unterschiedlichen Genauigkeitsstufen berechnet mit der IDP im Vergleich zur DDP Lösung

IDP für Energiemanagementstrategien: Wendet man die IDP bei der Berechnung optimaler Energiemanagementstrategien an, gilt es folgende Einschränkungen und Anpassungen zu beachten:

Wie in Abb. 5.7 zu sehen, ist die Kostenfunktion über die gesamte mögliche Batterieladung aufgespannt. Der Zustandsraum der Geschwindigkeitsstrategien lässt sich durch ein Fahrband stark einschränken. Bei der Energiemanagementstrategie ist dies nicht möglich. Um in jeder Iteration Zustandsübergänge zu ermöglichen, sind daher deutlich mehr Zustände nötig. Die Mindestanzahl der Zustände für die IDP-Methode ist weiterhin abhängig vom Energieinhalt einer Batterie und der elektrischen Leistung der E-Maschine, da diese die möglichen maximalen Zustandsübergänge festlegen.

Der Reduktionsfaktor γ wird im Bereich zwischen 0,95 und 0,99 gewählt, um eine hohe Qualität der Strategien zu erreichen. Die Mindestanzahl von Zuständen beträgt je nach Streckencharakteristik 200 Zustände.

5.4. Dynamische Programmierung im kontinuierlichen Zustandsraum

Neben dem Fluch der Dimensionen nennt BELLMAN ein weiteres Problem, das bei der praktischen Anwendung der DP auftritt: Die Gefahr des wachsenden Gitters. Es wird von LUUS [101, 115] aufgegriffen und als Interpolationsproblem bezeichnet. Wenn die Strategie von einem Gitterpunkt keinen exakten Gitterpunkt in der nächsten Stufe erreicht oder dieser außerhalb des Gitters und dem damit definierten Zustandsraum liegt, müssen solche Hyper- oder Zwischenzustände in der Regel wie in Abschnitt 5.2.1 beschrieben, interpoliert werden. Im mehrdimensionalen Zustandsraum ist damit aber auch eine mehrdimensionale Interpolation nötig. LAPIDUS zeigt in [101], wie zeitaufwendig eine Interpolation für eine dreidimensionale Interpolation innerhalb der DP werden kann. Anhand eines Beispiels lässt sich das Interpolationsproblem verdeutlichen.

5.4.1. Interpolationsproblem: Gewonnene Energie in der Optimierung

Wird in einem HEV rein elektrisch gefahren, so wird die Batterie über eine gewisse Distanz oder Zeit entladen. Ist der Entladewert der Batterie kleiner als der halbe Abstand zwischen zwei Batteriezuständen S_{x_k} , so wird bei der *Nächste Nachbar* - Methode (vgl. Abschnitt 5.2.1) das Ergebnis auf denselben Zustand gerundet (siehe Abb. 5.15). Obwohl sich das Fahrzeug vorwärts bewegt, wird durch die Rundung die Batterie nicht entladen. Wählt der Optimierer diesen Übergang, *gewinnt* er Energie [181]. Da selbst bei einer Interpolation nur von zuvor definierten Gitterpunkten weiter gerechnet wird, wird der Fehler δ in jedem Schritt größer.

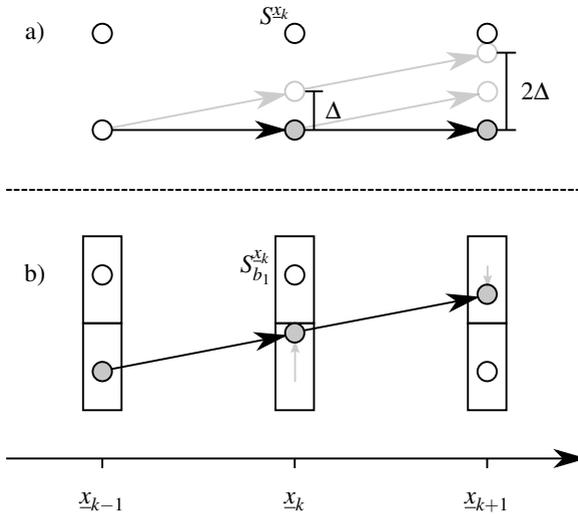


Abb. 5.15.: Interpolationsproblem: a.) Fehler Δ steigt bei der *Nächster Nachbar*-Methode an; b.) Gitter wird im kontinuierlichen Zustandsraum durch Boxen b angepasst [181].

Der Einfluss dieses Problems wird in der Regel durch eine feinere Diskretisierung reduziert. Das resultiert aber in einer größeren Anzahl von Zuständen je Dimension, wodurch die Rechenzeit und der Speicherbedarf stark ansteigen.

LUUS löst das Interpolationsproblem, indem der exakte Wert des neuen kontinuierlichen Zustands gespeichert wird und von diesem aus die folgenden Zustandsübergänge gerechnet werden [115, 101].

Wie in Abb. 5.16 zu sehen, wird so das Gitter, das den Zustandsraum definiert, an die betrachteten Übergänge angepasst und eine Optimierung in einem kontinuierlichen Zustandsraum ohne Interpolationsfehler ist möglich. Es wird der Begriff der Kontinuierlichen Dynamischen Programmierung⁵⁶ (CDP) eingeführt.

In einem kontinuierlichen Zustandsraum sind unendlich viele Übergänge und damit auch unendlich viele kontinuierliche Folgezustände möglich. LUUS generiert die relevanten Folgezustände, indem in jeder Stufe eine Anzahl von Steuergrößen zufällig ausgewählt werden und durch Iterationen das Optimum gefunden wird. Dies führt bei einer vorgegebenen Anzahl von Stufen und Iterationen nicht garantiert zum globalen Optimum [27].

Um ein globales Optimum zu finden, muss der gesamte Optimierungsraum abgedeckt sein. Dies ist bei der DDP durch eine gleichmäßige Abdeckung vieler Übergänge in alle Bereiche in einer Stufe gewährleistet.

⁵⁶ engl. Continuous Dynamic Programming

Aus diesem Grund kann in der Umsetzung der CDP das Boxen-Prinzip angewendet werden.

5.4.2. Boxen-Prinzip

Um in jeder Stufe dieselbe Anzahl von Zuständen zu speichern und gleichzeitig die Abdeckung des gesamten Zustandsraums zu gewährleisten, werden Boxen b eingeführt, die an die Stelle der diskreten Zustände bei der DDP treten und einen Bereich definieren, in dem mögliche kontinuierliche Folgezustände miteinander verglichen werden. In dieser Box wird lokal ausgewählt, mit welchem Zustand weiter gerechnet wird. Mit der DDP verglichen, repräsentieren somit alle Boxen ein mehrdimensionales Gitter, in welchem die jeweilige Position der Gitterknoten lokal an den kontinuierlichen Zustandsraum angepasst wird. Zur Rekonstruktion der Strategien ist es nötig, nicht nur die Kosten, sondern auch diese Position im Zustandsraum dem Zustandsvektor zuzuweisen. In Abb. 5.15 b.) ist das Boxen-Prinzip gezeigt. Die Abweichung wird korrigiert und der Zustand zum tatsächlichen Wert angepasst.

In Abb. 5.16 ist schematisch ein Optimierungsraum mit vier Boxen dargestellt. Da in jeder Box nur eine Strategie weiterverfolgt werden kann, ist die Anzahl der betrachteten Strategien in Stufe N identisch mit der Anzahl der verwendeten Boxen. Auch bei der DDP gilt dieser Zusammenhang zwischen der Anzahl der Zustände und der damit verbundenen Anzahl der möglichen Strategien. Wird die Anzahl der Boxen stark reduziert, so hat dies denselben Effekt wie bei einem weit diskretisierten Zustandsraum:

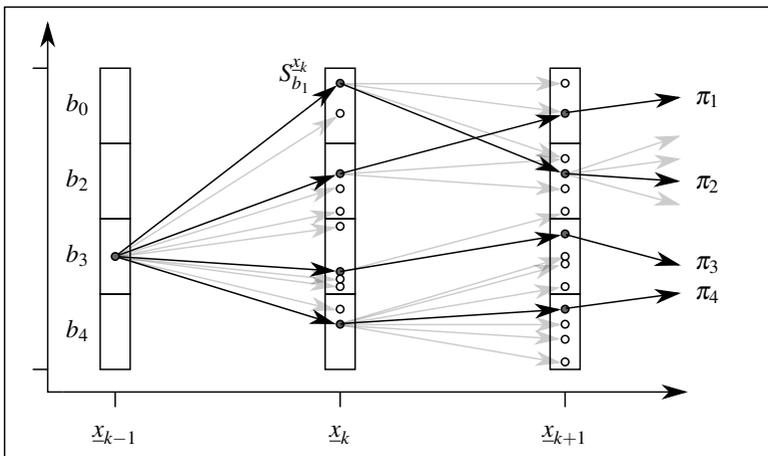


Abb. 5.16.: Repräsentation eines kontinuierlichen Zustandsraums mit vier Zustandsboxen

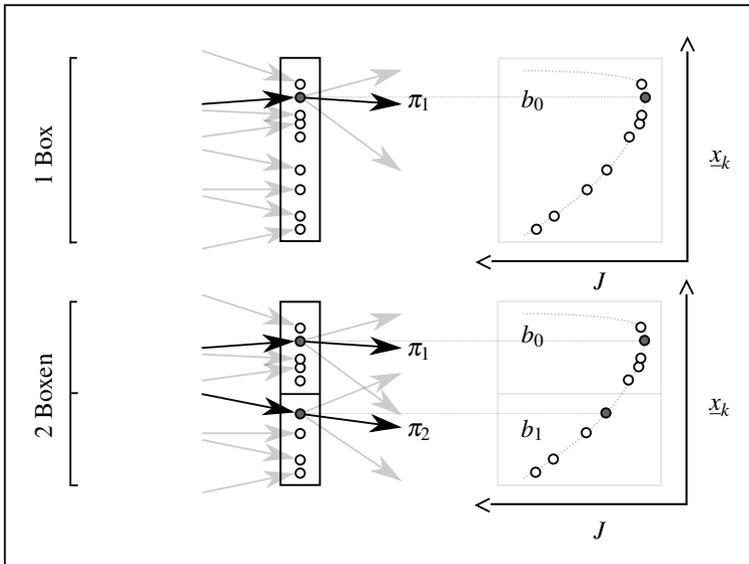


Abb. 5.17.: Zuweisung möglicher Zustände für unterschiedliche Boxengrößen

Die lokale Auswahl, welcher Zustand weiter verfolgt werden soll, entscheidet über das Gesamtergebnis. Eine globale Sichtweise ist nur vom Ende her möglich.

In Abb. 5.17 ist der Unterschied zwischen einer und zwei Boxen für den gleich großen Bereich im Zustandsraum schematisch dargestellt. Da in jeder Box nur der Zustand mit den minimalen Kosten J weiterverfolgt wird, ist es möglich, dass ein lokal suboptimaler Zustand verworfen wird, auch wenn dieser zu einer global optimalen Strategie beitragen würde.

Mit mehr Boxen werden damit mehr Informationen in jeder Stufe mitgeführt und es stehen damit mehr Strategien zur Auswahl. Wie bei der DDP löst das aber nicht den Fluch der Dimensionen, denn ein genaues Ergebnis erfordert viele Boxen und damit einen großen Speicher und viel Rechenzeit.

5.4.3. Bevorzugte Betrachtung lokal optimaler Zustandsübergänge

Neben dem kontinuierlichen Zustandsraum kann der Aktionsraum kontinuierlich betrachtet werden. Es sind damit unendlich viele Möglichkeiten von Zustandsübergängen (Aktionen) möglich. Die Anzahl der Aktionen bestimmt maßgeblich die Rechenzeit. Eine Vorauswahl muss getroffen werden.

LUUS wählt eine festgelegte Anzahl von Aktionen zufällig aus und versucht durch mehrere Iterationen, bei denen der Aktionsraum immer weiter um optimale Übergänge eingeschränkt wird, eine optimale Strategie zu finden [115]. Da bei vorliegender Problemstellung die Aktionen von der Stufe abhängen, ist diese Variante nicht möglich.

Eine weitere Möglichkeit besteht in der genaueren Betrachtung, welche Aktionen lokal für eine Stufe in Frage kommen. Das Ziel hierbei ist es, nur die Übergänge zu betrachten, die für die Optimierung relevant sein können. Für diese Vorauswahl können verschiedene Methoden verwendet werden, von denen zwei näher betrachtet werden:

- Lokale Optimierung
- Heuristiken und Regeln aus Modellwissen und Simulation

Lokale Optimierung

Ist von einem Zustand x_k ein lokal optimaler Folgezustand x_{k+1}^* bekannt und geht man von einer konvexen oder annähernd konvexen Form der Kostenfunktion für diese Folgestufe $k + 1$ aus, so kann die Anzahl der notwendigen Aktionen maximal auf die Anzahl der betrachteten Boxen beschränkt werden.

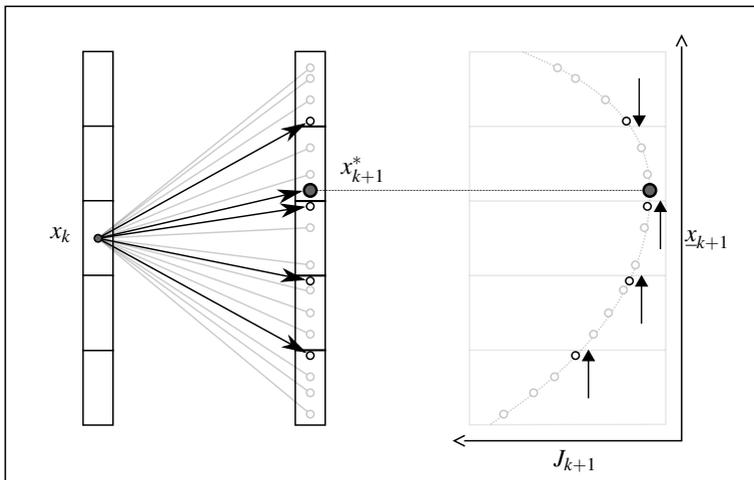


Abb. 5.18.: Reduktion der Berechnungen durch lokale Optimierung

Wie in Abb. 5.18 zu sehen, wird in der Box, in der sich der lokal optimale Zustand x_{k+1}^* befindet, nur die Aktion zu diesem Zustand ausgewählt. In den anderen Boxen werden nur Aktionen zu Zuständen ausgeführt, die der lokal optimalen Box am nächsten liegen.

Diese Zustände (schwarz) liegen an den Boxgrenzen. Andere Aktionen (grau) werden nicht weiter betrachtet. Damit ist sichergestellt, dass ein lokales Optimum für einen Zustandsübergang auf jeden Fall berücksichtigt wird. Die anderen Aktionen führen zu Zuständen, die innerhalb der Box dem lokalen Optimum am nächsten liegen.

Hier ist nur ein Zustandsübergang aus einer Box gezeigt. Da aus jeder Box in Stufe k zu allen Boxen in Stufe $k + 1$ eine Aktion berechnet wird, solange diese im Aktionsraum liegt, ist die Anzahl der Aktionen vergleichbar mit der in der klassischen DDP. Der entscheidende Vorteil ist das Verwenden von Modellwissen über lokal optimale Zustände bei der Auswahl der Aktionen.

Lokal optimale Zustandsübergänge können in vorberechneten Kennfeldern abgelegt werden, sodass nur ein Interpolationszugriff notwendig ist. Diese mehrdimensionalen Kennfelder werden in der Simulation erstellt, indem alle möglichen Zustandsübergänge betrachtet und bewertet werden. Für diese lokale Optimierung ist ein Gütemaß notwendig, bei dem z. B. der lokale Gesamtwirkungsgrad des Antriebsstrangs in Abhängigkeit des aktuellen Zustands (aktuelle Geschwindigkeit, Beschleunigung, Bordnetzleistung, Batterieladungszustand) bewertet wird.

Heuristiken

Die Reduktion des Suchraums (siehe Abschnitt 5.2.4) ermöglicht eine Reduktion der zu betrachtenden Zustände. Dabei werden zwischen maximalen und minimalen Grenzen im Fahrschlauch, die als *globale* Grenzen gelten, die Zustandsboxen äquidistant verteilt. Sind Eigenschaften optimaler Strategien bekannt, kann dieses Wissen genutzt werden, um die Größe der Zustandsboxen anzupassen. Dabei werden Bereiche, in denen kleinere Boxen festgelegt werden, hervorgehoben und Bereichen mit großen Boxen weniger Beachtung geschenkt. Die Informationsdichte, die einer Suchregion zugeteilt wird, kann so deutlich erhöht werden oder aber, um Rechenzeit zu sparen, an anderer Stelle reduziert werden. Mit dieser Heuristik kann die Suche nach einer optimalen Strategie beschleunigt werden. Dabei hat das Hervorheben optimaler Bereiche durch eine größere Anzahl von Boxen große Auswirkungen auf die Optimalität. Werden die falschen Bereiche begünstigt, wird eine globale Optimalität beeinträchtigt.

In Abb. 5.19 ist ein Optimierungsraum für eine optimale Geschwindigkeitsstrategie dargestellt. Als obere Grenze ist eine gesetzliche Geschwindigkeitsbeschränkung eingezeichnet. Maximale Beschleunigungen und minimale Verzögerungen reduzieren den Suchraum bei Schilderwechseln (a). Die grauen Linien stellen 5 Boxen dar, deren Größe durch eine Heuristik angepasst ist. Die gewählte obere und untere Grenze (b) wird aus der vorigen Stufe berechnet. Dabei werden aus dem maximal und minimal gewählten Zustand in Stufe k die oberen und unteren Grenzen der Boxen in $k + 1$ bestimmt. Der Zustandsraum baut sich während der Optimierung auf, sodass Bereiche, die unwahrscheinlich oder gar nicht zu erreichen sind, nicht einbezogen werden.

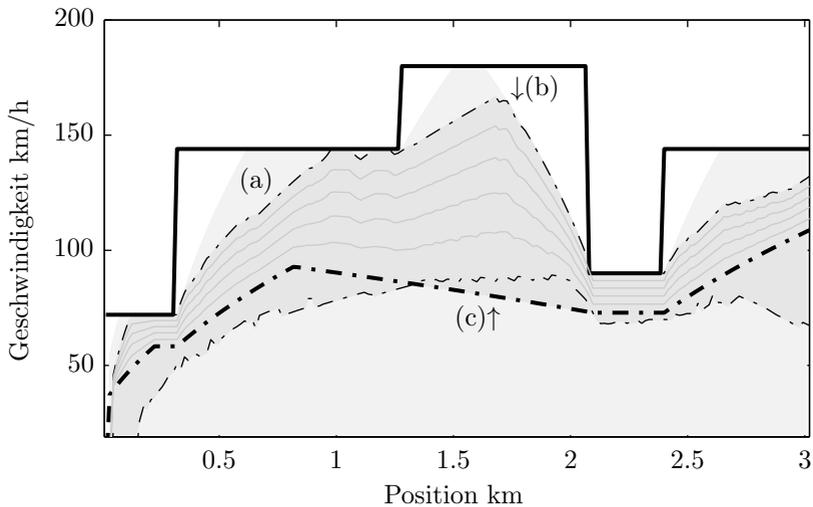


Abb. 5.19. Kontinuierlicher Optimierungsraum mit fünf Boxen, globale (a) und lokale (b) Reduktion und Segelstrategie (c) als Heuristikvorgabe [181].

Für die Aufteilung der Boxen dient eine heuristisch bestimmte Geschwindigkeit als Führungsgröße (c), die eine energetisch sinnvolle Segelstrategie darstellt. Zwischen dieser und der maximalen Geschwindigkeit befinden sich die Mehrheit der Boxen. Dieser Bereich wird durch mehr mögliche Strategien in der Optimierung herausgestellt.

Fehlende Vorgabe bei der Batterieladungsstrategie

Bei der Optimierung mit dem Boxen-Prinzip und wenigen Zustandsboxen ist eine Heuristik erforderlich. Während bei der Fahrstrategie der verwendete Fahrschlauch den Optimierungsraum einschränkt, um eine gewünschte mittlere Zielgeschwindigkeit zu erreichen, lässt sich bei der Batterieladungsstrategie eine heuristische Einschränkung in Form eines Schlauchs (SoC-Band) nur schwer durch Regeln von der Geschwindigkeit und der Routentopografie von einem Schritt k auf den anderen $k + 1$ ableiten.

Ein Fehlen dieses SoC-Bands bewirkt bei wenigen Zustandsboxen ein Entladeverhalten ähnlich einer heuristischen Strategie. Da die Grenzen der Boxen aus den maximal und minimal möglichen Vorgängerzuständen berechnet werden, dominieren die lokal optimalen Zustandsübergänge. Ein Halten der Batterieladung ist aus lokal optimaler Sicht nicht sinnvoll und wird erst über die gesamte Distanz betrachtet ausgewählt. Sind nur wenige Boxen vorhanden, hat die lokale Optimierung einen starken Einfluss, der durch eine Vergrößerung der Anzahl der Boxen reduziert werden kann. Dies ist jedoch durch den dadurch steigenden Speicheraufwand nicht erwünscht.

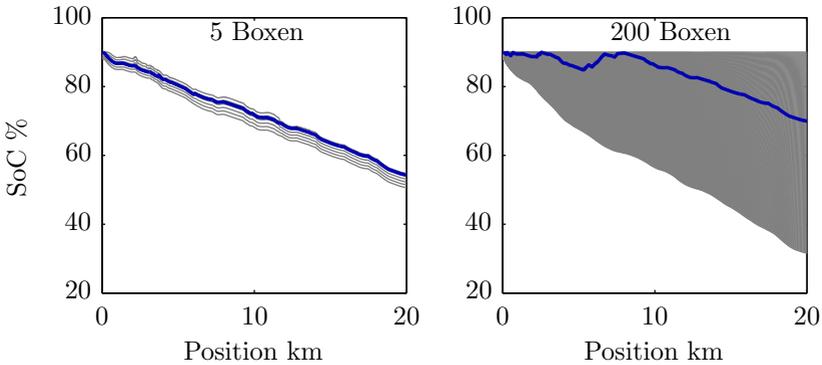


Abb. 5.20.: Batterieladungsstrategie beim Boxen-Prinzip für eine unterschiedliche Anzahl von SoC-Boxen

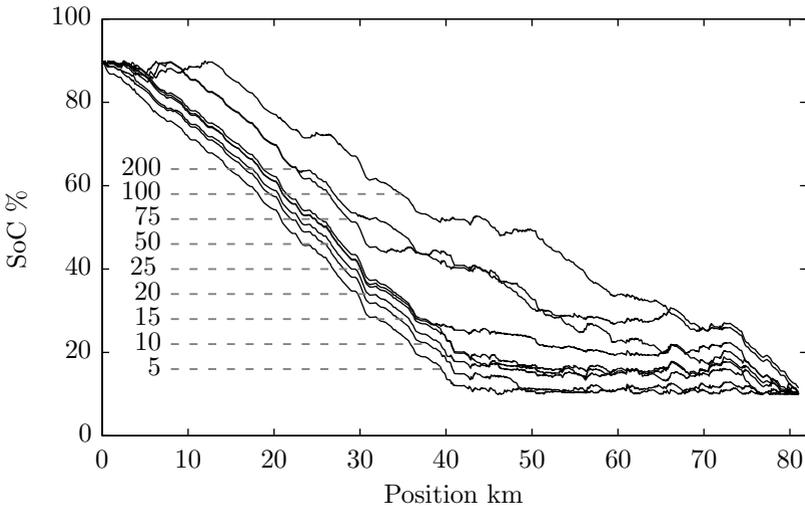


Abb. 5.21.: Batterieladungsstrategie beim Boxen-Prinzip ohne Heuristik (SoC-Schlauch) mit unterschiedlicher Anzahl von Zustandsboxen

In Abb. 5.20 sind die ersten 20 km einer Strategie mit 5 bzw. 200 SoC-Boxen abgebildet. Eine Vergrößerung der Anzahl der Zustandsboxen bedeutet, dass weniger Zustandsübergänge in einer Box zusammengefasst werden. Es ist dadurch möglich, mehr lokal suboptimale Zwischenergebnisse zu speichern, die bei einer globalen Be-

trachtung ausgewählt werden können. Die Spreizung zwischen unterer und oberer Grenze des betrachteten Zustandsraums nimmt zu.

In Abb. 5.21 sind optimale Strategien für eine unterschiedliche Anzahl von SoC Boxen abgebildet. Bei einer größeren Anzahl von Zustandsboxen verschwindet der Einfluss der lokalen Auswahl in den Boxen zunehmend. Da mit mehr Zustandsboxen auch die Speichergröße sowie die Rechenzeit steigen, ist die Einführung eines SoC-Bandes notwendig, das den Zustandsraum des Optimierers auf den relevanten Bereich begrenzt. Zum Erstellen dieses SoC-Bandes können Optimierungsmethoden verwendet werden, die nicht auf dem Boxen-Prinzip beruhen (DDP, IDP). Dieses SoC-Band ermöglicht das Halten eines Batterieladezustands auch mit wenigen SoC-Zustandsboxen.

5.4.4. Mehrdimensionaler Zustandsraum

Die Einführung von Boxen in der DP ist gerade in mehrdimensionalen Zustandsräumen von Vorteil. Durch gezielte Einschränkung des Zustandsraums auf Bereiche relevanter Zustandsübergänge und durch Einsatz genannter Heuristiken kann die Anzahl der Boxen pro Zustandsraum reduziert werden.

In Abb. 5.22 ist ein Zustandsübergang in einem zweidimensionalen Zustandsraum schematisch dargestellt. Es werden $B^a = 4$ Boxen für die Beschleunigung gewählt. Die Anzahl der Boxen für die Geschwindigkeit beträgt $B^v = 7$.

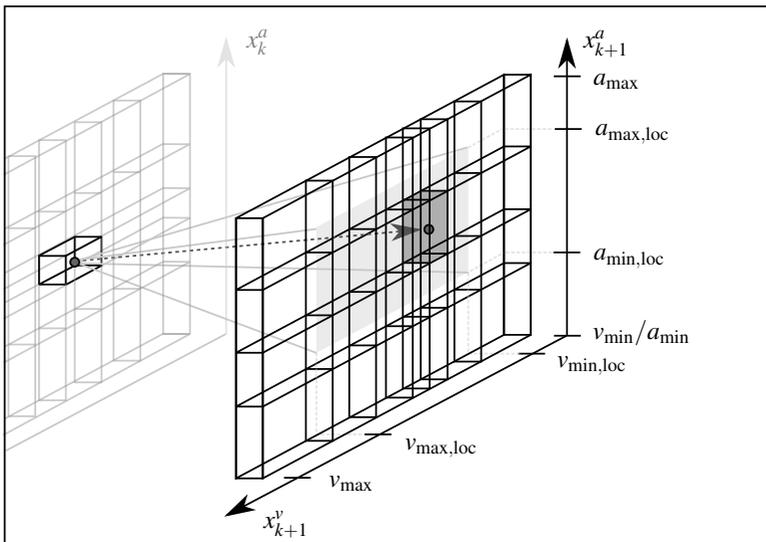


Abb. 5.22.: Lokale Einschränkung bei mehrdimensionalen Zustandsboxen

Während die Boxgrenzen (v_{\min} , v_{\max} , a_{\min} , a_{\max}) positionsabhängig für jede Stufe k bestimmt werden, kann die Berechnung der möglichen Zustandsübergänge aus dem Zustand x_k weiter eingeschränkt werden. Für die Berechnung des Zustandsübergangs werden nur die Boxen betrachtet, die unter vorgegebenen Bedingungen erreicht werden können. Komforteigenschaften wie Maximalbeschleunigungen aber auch der maximale Ruck schränken den relevanten Bereich der lokal möglichen Beschleunigungen ein ($a_{\min,loc}$, $a_{\max,loc}$). Die Einschränkung der Beschleunigung aus Komfortgründen definiert unter anderem wiederum mögliche maximale ($v_{\max,loc}$) und minimale ($v_{\min,loc}$) Geschwindigkeiten für diesen Zustandsübergang. Die Aufteilung der Boxgrößen kann wie in Abschnitt 5.4.3 beschrieben, in relevanten Bereichen verdichtet werden. Dieser Vorgang hat keine Auswirkung auf die Festlegung der lokalen Einschränkungen, jedoch auf die Speicherdichte in einer Zustandsregion pro Stufe.

Die Anzahl der Boxen für jede Dimension hat entscheidenden Einfluss auf das Optimierungsergebnis, das über die Gesamtkosten J^* bewertet werden kann. In Abb. 5.23 sind die Gesamtkosten für einen 3 km langen Streckenabschnitt und einer Variation der Anzahl der Boxen dargestellt. Die Gesamtkosten sind auf den Minimalwert der Untersuchung normiert, sodass $J^* = 1$ (100 %) das beste Ergebnis darstellt. Werden alle Berechnungen mit den Gesamtkosten $J^* = 0,9$ (90 %) betrachtet, nähert sich die Anzahl der Boxen für Geschwindigkeiten asymptotisch gegen $B^v = 5$, die der Beschleunigungen gegen $B^a = 8$. Das dynamische Verhalten der Beschleunigung lässt sich schwerer durch eine Heuristik einschränken als die Geschwindigkeit. Diese benötigt bei dieser Untersuchung deshalb weniger Boxen als die Beschleunigung.

Das Anwenden von Heuristiken zur Anpassung der Zustandsboxen hat ein „Rauschen“ der Ergebnisse zur Folge. Durch das Hinzufügen einer weiteren Zustandsbox kann die Strategie durch die gewählte Heuristik lokal abweichen und damit eine Verschlechterung der Gesamtkosten bewirken. Durch eine Verbesserung der Heuristik lässt sich dieses Rauschen reduzieren.

5.4.5. Iterative Berechnung

Die DP im kontinuierlichen Zustandsraum kann mit der iterativen Einschränkung des Zustandsraums kombiniert werden. Dabei wird, wie bei der IDP, ein Reduktionsfaktor γ eingeführt, der den Zustandsraum um eine berechnete Strategie in jeder Iteration reduziert. In Abb. 5.24 sind die Gesamtkosten für eine Optimierung eines Streckenabschnitts als Variation des Reduktionsfaktors und der Anzahl der Iterationen R_{CDP} dargestellt. Die Kosten sind auf die maximalen ($J^* = 0$) und minimalen Werte ($J^* = 1$) innerhalb der Untersuchung normiert. Wie auch bei der Untersuchung der Variation der Anzahl der Boxen sind die Gesamtkosten mit einem stochastischen Rauschen überlagert, welches sich durch die lokale Optimierung und die verwendete Heuristik erklären lässt.

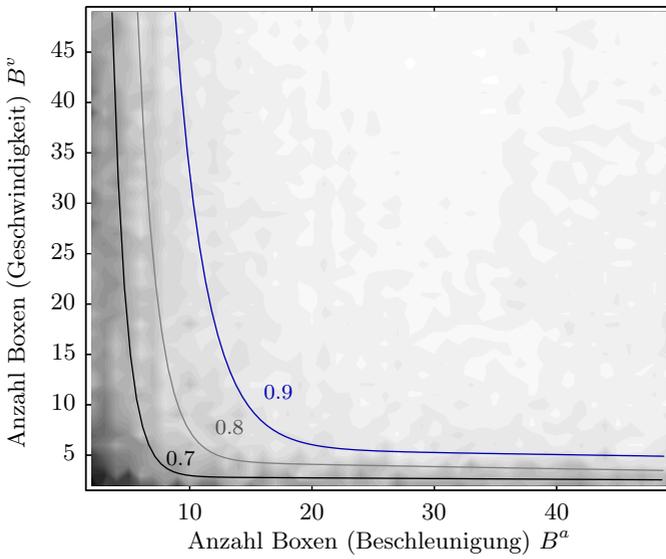


Abb. 5.23.: Normierte Gesamtkosten J^* für eine unterschiedliche Anzahl von Boxen im mehrdimensionalen Zustandsraum [181]

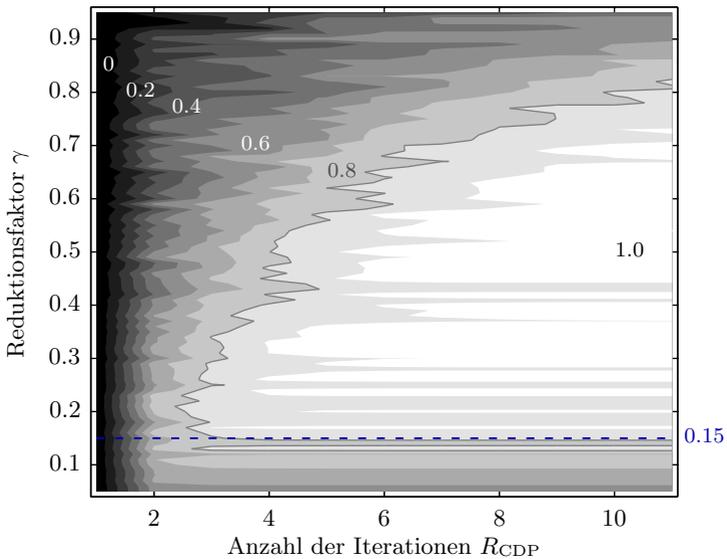


Abb. 5.24.: Normierte Gesamtkosten J^* für eine Variation des Reduktionsfaktors γ und der Anzahl der Iterationen bei der iterativen Ausführung des Boxen Verfahrens [181].

Im Gegensatz zur IDP führt eine große Reduktion des Zustandsraums von $\gamma = 15\%$ in wenigen Iterationen zu einer deutlichen Verbesserung der Gesamtkosten auf $J^* = 0,8$. Unterhalb dieses Wertes wird der Zustandsraum zu stark eingeschränkt, sodass die Strategien in lokalen Optima verlaufen. Entscheidend für die Optimalität der Strategien und der damit verbundenen Gesamtkosten sind die Heuristiken und lokale Optimierungen. Sind diese gut gewählt, kann in nur wenigen Iterationen das Ergebnis verbessert werden. Sie können aber auch dazu führen, dass die Gesamtkosten bei mehreren Iterationen nicht minimiert werden können (siehe $\gamma = 0,45$). Ein weiterer, entscheidender Einfluss stellt auch hier die Anzahl der Boxen je Zustand dar, die in diesem Beispiel nicht weiter untersucht werden.

Der Ablauf einer DP nach dem Boxen-Prinzip ist in Algorithmus 4 beschrieben. Das Prinzip der einzelnen Schleifendurchgänge in jeder Distanzstufe ist identisch zur DDP Berechnung. Durch den Reduktionsfaktor γ werden die Grenzen des mehrdimensionalen Zustandsraums in jeder Iteration weiter eingeschränkt. Das Berechnen der Boxgrenzen (b_{\min} , b_{\max}) sowie der kontinuierlichen Zustandsgrößen in diesen Boxen beinhaltet höheren Rechenaufwand verglichen mit der DDP. Diese zusätzliche Rechenzeit ist vernachlässigbar im Vergleich zur großen Reduktion der Anzahl der Boxen anstelle von diskreten Zuständen.

Algorithmus 4 : Das Boxen - Prinzip**Input** : Globale Boxgrenzen b_{\min}, b_{\max} ,Anzahl der Boxen B ,Reduktionsfaktor γ **Output** : Kostenfunktion J **begin** $l := 0$ **while** $J_{l+1}^* \neq J_l^*$ **do**

$$\mathcal{X}_0^l = \{\underline{b}, | \underline{b}_{\min}(0) \leq b_i \leq \underline{b}_{\max}(0) ; i = 0, \dots, B-1\}$$

for $k = 0 : N-1$ **do**// Zustandsboxen b für $k+1$:

$$\mathcal{X}_{k+1}^l := \{\underline{b}, | b_{\min} \leq b_i \leq b_{\max} ; i = 0, \dots, B-1\}$$

$$\hat{f}_{k+1}^{B \times N}(x) := \infty \quad \forall x_i \in \mathcal{X}_k^l, i = 0, 1, \dots, B-1$$

$$\hat{J}_{k+1}(x_k) := \min_{\mu_k} \{ \xi_k(x_k, \mu(x_k)) + \hat{J}_k(x') \} \Big|_{x_k \in \mathcal{X}_{k+1}^l, x' \in \mathcal{X}_k^l}$$

$$b_{\min} \leftarrow \min(x_k) \quad // \text{ Update Boxgrenzen für } k+1$$

$$b_{\max} \leftarrow \max(x_k)$$

$$J_{l+1}^* := \min \{ \hat{J}_N \} \quad // \text{ Optimale Kosten in } N$$

$$r_{l+1} := \gamma \cdot r_l \quad // \text{ Suchregion wird verkleinert}$$

// Anpassung der Grenzen um optimale Zustandsfolge \underline{x}^* :

$$\underline{b}_{\min}^{l+1} := \underline{x}^* - \frac{r_{l+1}}{2}$$

$$\underline{b}_{\max}^{l+1} := \underline{x}^* + \frac{r_{l+1}}{2}$$

 $l := l + 1$

5.5. Approximierte Dynamische Programmierung

Die Idee der Dynamischen Programmierung wird seit BELLMAN stetig weiterentwickelt und in verschiedenen Bereichen auf unterschiedliche Aufgabenstellungen angewendet. Auf der Suche nach Lösungen für mehrdimensionale und große DP Probleme werden verwandte Algorithmen unterschiedlich bezeichnet⁵⁷: *Approximate/Adaptive Dynamic Programming*, *Neuro-Dynamic Programming* oder *Reinforcement Learning* [23]. Die hier verwendeten Algorithmen werden unter dem Begriff der Approximierten Dynamischen Programmierung (ADP) zusammengefasst.

ADP kann je nach Problemstellung von unterschiedlichen Perspektiven betrachtet werden: Sie bietet eine Anzahl algorithmischer Strategien, um komplexe dynamische Programme zu lösen. Klassische Simulationen können durch Optimierungsverfahren präziser aufgebaut werden. ADP bietet für groß dimensionierte mathematische Programme Methoden zur Zerlegung der Problemstellung an [135].

Der Fluch der Dimensionen wurde oft umgangen, indem das Originalproblem aggregiert⁵⁸ wurde, um die Größe des Zustandsraums zu reduzieren. Dabei werden zum Beispiel Modellvereinfachungen und mathematische Beschreibungen wie der Lagrange Multiplikator [145, 12] verwendet. Das aggregierte Problem lässt sich dann mit der klassischen DP lösen und die Lösung desaggregieren⁵⁹. Damit wird die Problemstellung vereinfacht, während die Kostenfunktion beibehalten wird [135]. Drei Formen der Approximation können nach Bertsekas unterschieden werden [21]:

- Approximation des Problems (Problem Approximation): Vereinfachung des Problems und Lösung des aggregierten Problems.
- Rollout Ansatz (Rollout Approach): Durch Simulation oder analytische Verfahren werden Strategien approximiert, die zu einer Lösung führen.
- Parametrische Schrittkosten Approximation (Parametric Cost-to-Go Approximation): Die Kostenfunktion wird durch eine Funktion in parametrischer Form approximiert.

ADP bietet durch die Parametrische Schrittkosten Approximation die Möglichkeit, die Kostenfunktion des komplexen Problems zu erhalten, indem diese an Stelle der gesamten Problemstellung vereinfacht beschrieben wird. BELLMAN hat schon früh die Approximation von Funktionen⁶⁰ als vielversprechende Methode aufgrund fehlenden Speichers vorgeschlagen [20]. Die von ihm beschriebene Vorgehensweise legt die Grundlage der hier vorgestellten Verfahren.

⁵⁷ In [169] werden einige Bezeichnungen genannt, darunter: Approximate Dynamic Programming [135, 159, 170], Adaptive Dynamic Programming [126, 127] Neuro-Dynamic Programming [24], Reinforcement Learning [165].

⁵⁸ engl. Aggregate = vereinen

⁵⁹ engl. Disaggregate = zerlegen

⁶⁰ engl. Functional Approximation

5.5.1. Approximation der Kostenfunktion

Es gibt mehrere Gründe die Kostenfunktion zu approximieren. Die Kostenfunktion $J^{L \times N}$ wird in der klassischen DDP im Code durch eine diskrete Kostenmatrix abgebildet. Dabei können zum einen eine große Anzahl an Zuständen L (oder Boxen B) aber auch die Mehrdimensionalität I zum Fluch der Dimensionen führen. Da die Kostenmatrix maßgeblich für den benötigten Speicher bei der Optimierung verantwortlich ist, wird dieser durch eine Approximation deutlich reduziert. Eine Dimension der Kostenmatrix sind die N Stufen über der Distanz. Sie haben einen linearen Anteil am Speicherbedarf der Kostenmatrix, der gerade bei der Berechnung von optimalen Strategien über weite Entfernungen sehr groß sein kann [183].

Für eine möglichst genaue Repräsentation der Kostenmatrix wird in der ADP eine Basisfunktion gesucht, die mit möglichst wenigen Eigenschaften⁶¹ die Kostenfunktion beschreiben kann. Es gibt unterschiedliche Verfahren aus der Bildverarbeitung, um Eigenschaften in Form von Mustererkennung⁶² einer Basisfunktion zuzuweisen.

Aufgrund der Form der betrachteten Kostenfunktionen wird für die Approximation der Kostenmatrix eine polynomiale Basisfunktion gewählt. Für das Anpassen⁶³ der Funktion wird eine Regressionsanalyse verwendet.

Regressionsanalyse

Mittels linearer Regression wird eine Basisfunktion gesucht, die die Kostenmatrix möglichst gut abbildet und schnell zu berechnen ist. Zur Vereinfachung der Problemstellung wird die Kostenmatrix nicht als Ganzes angepasst, sondern nur die Werte der Kostenfunktion in jeder Stufe durch ein Polynom dargestellt. Dadurch vereinfacht sich die Regressionsanalyse einer mehrdimensionalen Datenmenge auf eine eindimensionale Betrachtung in jeder Stufe. Das ermöglicht eine höhere Genauigkeit bei gleichzeitiger Reduktion der Rechenzeit.

Ziel der Regressionsanalyse ist es, mit einer möglichst geringen Anzahl S von beobachteten Zuständen \underline{x} eine polynomiale Beschreibung der Kostenfunktion $J_k(\underline{x})$ in Stufe k zu erlangen. Das Regressionsmodell dazu lautet [135]:

$$J'_k(x_k) = \Theta_k^T x_k = \sum_{j=0}^Z \Theta_{k,j} x_k^j \quad (5.21)$$

$J'_k(x)$ repräsentieren die geschätzten Kosten und Θ'_k ist der gesuchte Parametervektor. Der zu minimierende Fehler ε_k (Residuum) ist die Abweichung zwischen den geschätzten und beobachteten Kosten:

$$\varepsilon_k = (J_k - J'_k) \quad (5.22)$$

⁶¹ engl. Feature: Ein Begriff aus dem Bereich der Künstlichen Intelligenz (KI)

⁶² engl. Feature Extraction

⁶³ engl. Fitting

Durch die *Methode der kleinsten Quadrate*⁶⁴ wird der Parametervektor so geschätzt, dass die quadrierten Residuen minimal werden [13]:

$$\min_{\Theta_k} \sum_{m=1}^S (J_{k,m} - J'_{k,m})^2 \quad (5.23)$$

Der optimale Parametervektor Θ^* wird durch eine sogenannte Batch-Routine berechnet und lautet in Matrixschreibweise [65]:

$$\Theta^* = [(X^S)^T X^S]^{-1} (X^S)^T Y^S, \quad (5.24)$$

wobei

$$X_k^S = \begin{pmatrix} x_0^1 & x_1^1 & \cdots & x_Z^1 \\ x_0^2 & x_1^2 & \cdots & x_Z^2 \\ \vdots & \vdots & \ddots & \vdots \\ x_0^S & x_1^S & \cdots & x_Z^S \end{pmatrix} \quad (5.25)$$

die $S \times Z + 1$ Zustandsmatrix und

$$Y_k^S = \begin{pmatrix} J_k^1 \\ J_k^2 \\ \vdots \\ J_k^S \end{pmatrix} \quad (5.26)$$

der Kostenvektor nach S Beobachtungen in Stufe k ist.

Ordnung des Polynoms

Die Ordnung des Polynoms ist gleich der Anzahl der Eigenschaften zur Schätzung der Kostenfunktion. Je höher die Ordnung, desto genauer ist die Schätzung, aber auch desto aufwendiger ist die Berechnung. Teil der Berechnung des Parametervektors beinhaltet eine Matrixinversion, die für ein Polynom dritter Ordnung durch eine explizite Form berechnet werden kann. Bei höherer Ordnung wird die Lösung über das GAUSSSche Eliminationsverfahren numerisch berechnet, was in einem höheren Rechenaufwand je Anpassung resultiert.

In Abb. 5.25 ist die Kostenfunktion J^{fit} der ersten 15 km des Referenzzyklus in polynomialer Form (oben) im Vergleich zur Kostenmatrix J^M (unten) für die Berechnung der Geschwindigkeitsstrategie dargestellt. Die optimale Geschwindigkeitsstrategie ist über die Distanz eingezeichnet. Es ist zu erkennen, dass die Strategie nicht zwangsläufig durch die kostengünstigsten Bereiche in jedem Distanzschritt verläuft (Minimum in jeder Stufe grün eingezeichnet), sondern aus global optimaler Sicht einen Verlauf wählt, der über die ganze Strecke aufsummiert in den minimalen Kosten resultiert.

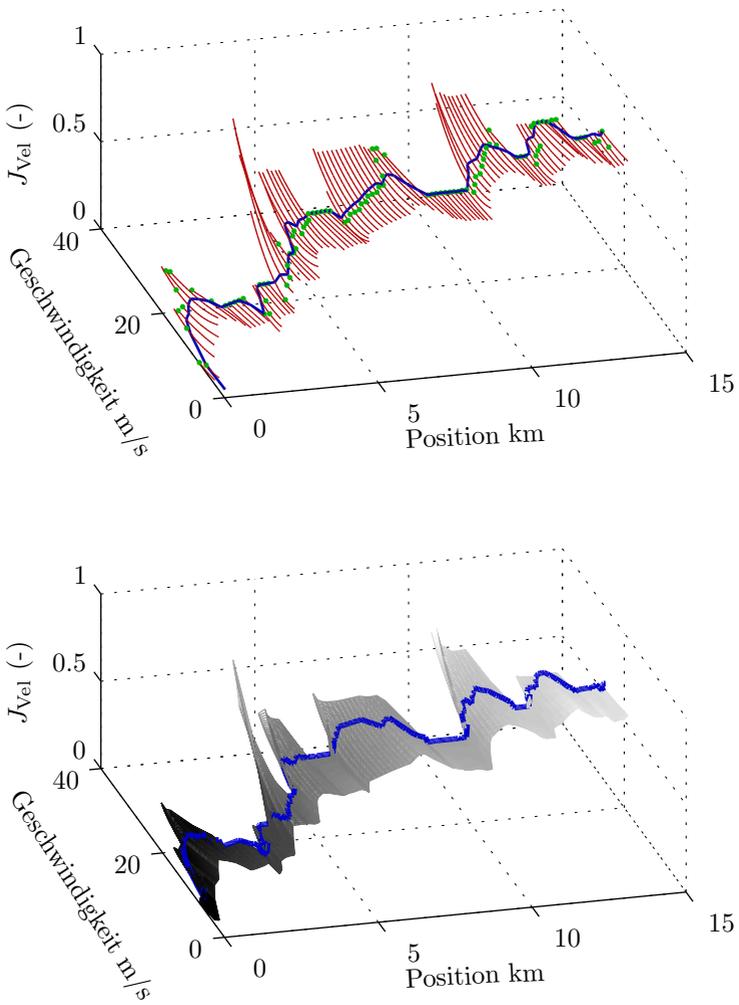


Abb. 5.25.: Die Kostenfunktion für die Geschwindigkeitsstrategie auf den ersten 15 km des Referenzzyklus durch polynomiale Basisfunktionen angepasst (oben) sowie in Matrixform (unten).

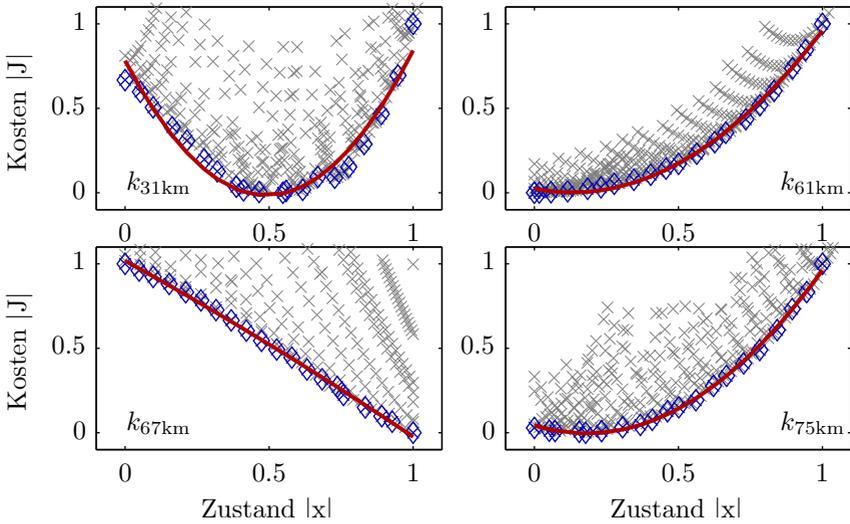


Abb. 5.26.: Einzelne Basisfunktionen der Kostenfunktion für die Geschwindigkeitsstrategie angepasst an die minimalen Kosten in einer Distanzstufe k . Die Kosten sind über den normierten Zuständen (Kreuz) aufgetragen.

Die angepassten Basisfunktionen sind nur im Bereich des Zustandsraums definiert, sodass die obere \mathcal{X}_{\max} und untere Begrenzung \mathcal{X}_{\min} des Zustandsraums mitgeführt werden muss. Bei Änderungen der oberen Geschwindigkeitsbegrenzung (z. B. bei 10 km) wird eine zu starke Beschleunigung durch hohe Kosten bestraft, die wiederum in einem großen Gradienten in der Kostenmatrix resultiert. Da eine Basisfunktion für jede Distanzstufe über den eindimensionalen Zustandsraum in k neu angepasst wird, werden großen Gradienten zwischen zwei Stufen nicht geglättet, sondern genau übernommen.

In Abb. 5.26 sind für vier exemplarische Distanzstufen angepasste Basisfunktionen sowie die einzelnen Schrittkosten für diese Distanzstufe und für alle betrachteten Zustände abgebildet. Die bei einem Zustandsübergang entstehenden Kosten sind durch Kreuze dargestellt. Sie weisen je nach Stufe eine andere Verteilung über dem Zustandsraum auf. Dieses Muster ist durch die Straßentopologie sowie das Fahrzeugmodell zu begründen und beinhaltet nicht nur die lokalen Kosten, sondern auch die aufsummierten Kosten bis zu dieser Distanzstufe.

Für die Weiterberechnung sind nur die minimalen Kosten in jedem Zustand relevant (Raute). Nur diese Kosten werden für die Anpassung der Basisfunktion herangezogen. Für die in Abb. 5.26 gezeigten Basisfunktionen wird ein Polynom 2. Grades gewählt.

⁶⁴ engl. Least-Squares Estimation

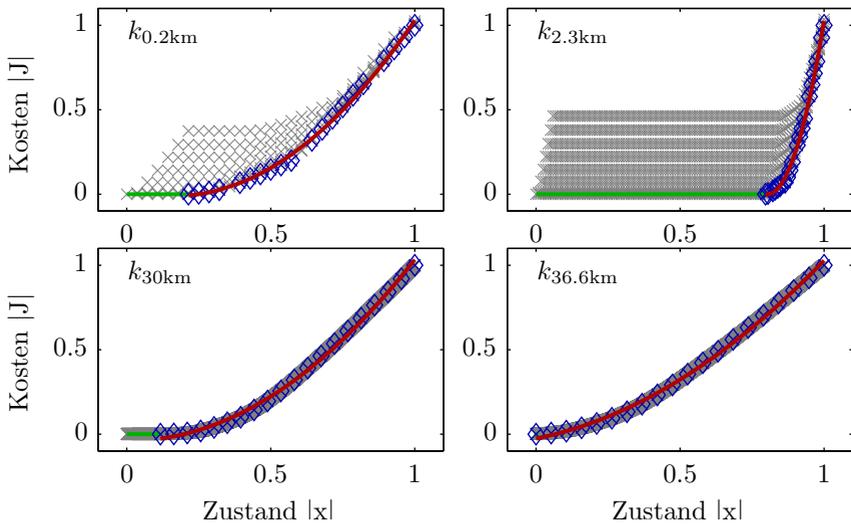


Abb. 5.27.: Einzelne Basisfunktionen der Kostenfunktion für die Batterieladungsstrategie angepasst an die minimalen Kosten in einer Distanzstufe k . Die Kosten sind über die normierten Zustände (Kreuz) aufgetragen.

Eine Untersuchung zur Güte der gewählten Basisfunktion über den gesamten Referenzzyklus folgt in Abschnitt 5.5.4.

Die Normierung der Kosten und der Zustände auf den relevanten Bereich pro Stufe resultiert in einer höheren Signifikanz der Ergebnisse. Zur Rekonstruktion sind die Grenzen deshalb mitzuführen. Alle N angepassten Basisfunktionen stellen so die komplette Kostenfunktion über N Stufen dar und ersetzen die Kostenmatrix.

Anwendung Batterieladungsstrategie: Die Kostenfunktion unterscheidet sich je nach Parametrierung und Aufgabenstellung. Während bei der Optimierung der Fahrstrategie sowohl die Zeit als auch die Energie am Rad bewertet wird, fließt in die Batterieladungsstrategie die energetische Betrachtung des Antriebsstrangs ein. Die Form der Kostenfunktion ändert sich und somit auch die Basisfunktion bei der ADP.

In Abb. 5.27 sind vier Distanzstufen k der Kostenfunktion für den Referenzzyklus dargestellt. Die minimalen Kosten sind durch stückweise Basisfunktionen angepasst. Diese bestehen aus einer linearen Funktion und einer Polynomfunktion bis zur 2. Ordnung. Im Gegensatz zur Kostenfunktion der Fahrstrategie, weisen die einzelnen Kosten pro Zustandsübergang Strukturen auf, die sich über die gesamte Strecke verändern.

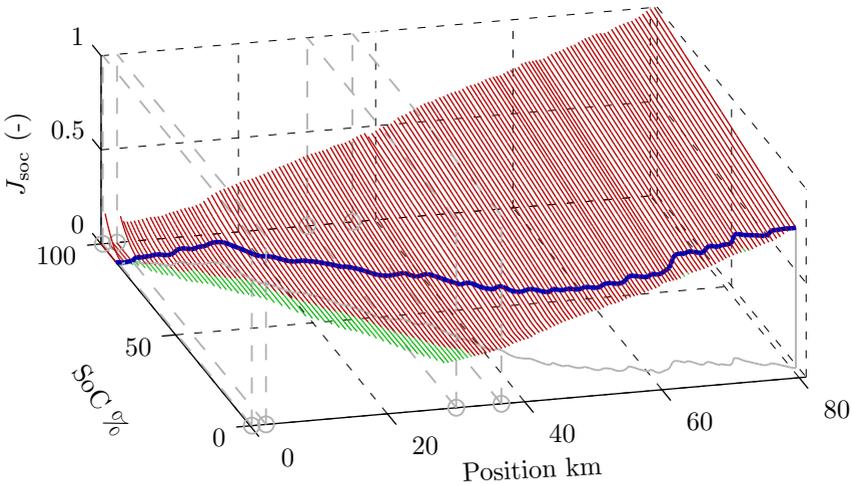


Abb. 5.28.: Angepasste Kostenfunktion der Batterieladungsstrategie für den Referenzzyklus aus einzelnen Basisfunktionen zusammengesetzt. Die Optimale Batterieladungsstrategie ist über die Distanz eingezeichnet (blau).

Die Grenze zwischen dem linearen Anteil der minimalen Kosten (grün) und der stark gegen eins ansteigenden Kosten (rot) verschiebt sich auf den ersten 36 km des Referenzzyklus.

Diese typische Aufteilung der Kostenfunktion in einen linearen und nicht-linearen Anteil lässt sich bei Batterieladungsstrategien wie folgt erklären:

Linearer Anteil (grün): Rein elektrisches Fahren wird in der Kostenfunktion mit Schrittkosten gleich null bewertet, sodass von jedem Zustand, von dem Fahren ohne Verbrennungsmotor möglich ist, die minimalen Kosten normiert null ergeben⁶⁵.

Nicht-linearer Anteil (rot): Beim Nachladen der Batterie durch Lastpunktverschiebung läuft der Verbrennungsmotor, wodurch Kosten entstehen, die mit zunehmendem Batterieladezustand wachsen.

Wird die elektrische Reichweite (AER) erreicht, verschwindet der lineare Anteil in den Basisfunktionen. In Abb. 5.28 sind alle Basisfunktionen im Abstand von je 20 Stufen für den gesamten Referenzzyklus dargestellt. Der lineare Anteil der Basisfunktionen verläuft weitgehend parallel zur unteren maximalen Entladestrategie für

⁶⁵ Wird der elektrische Strom aus der vollgeladenen Batterie mit Stromkosten aus dem Netz in der Kostenfunktion bewertet, dann lassen sich diese Kosten anstatt mit einer konstanten Funktion mit einer linearen Funktion abbilden

eine anfängliche Batterieladung von $\text{SoC}_{\text{start}} = 90\%$ bei Distanz $k = 0$. Die optimale Batterieladungsstrategie für eine minimale Batterieladung am Ende des Zyklus von $\text{SoC}_{\text{end}} = 5\%$ ist eingezeichnet.

5.5.2. Approximation der Pfadrückverfolgung

Für viele Anwendungen der DP stellt die Kostenfunktion in Stufe N die Lösung dar. Bei der Suche nach optimalen Regelungen dient das Minimieren der Kostenfunktion dazu, einen optimalen Steuerverlauf zu finden. Um aus einer Kostenfunktion die Strategie zu extrahieren, wird bei der praktischen Umsetzung eine Pfadmatrix herangezogen, in der zu jedem Punkt in der Kostenmatrix der zugehörige Vorgängerknoten abgespeichert ist. Der Vorgang der Pfadrückverfolgung wird auch als Rückwärtsrechnung bezeichnet (siehe Abschnitt 5.2.6).

Diese Pfadmatrix stellt neben der Kostenmatrix eine der zwei großen Speicherressourcen dar. Für einen eindimensionalen Zustandsraum mit einer Diskretisierung von $L = 100$ Zuständen und $N = 1000$ Stufen wird als Beispiel bei einem Integer Datentyp 98 Kilobytes an Speicherreservierung benötigt, um von jedem Kostenknoten den Vorgängerzustand zu speichern.

Im Folgenden wird eine Methode vorgestellt, die es erlaubt die Pfadrückverfolgung zu approximieren. Dabei entfällt die speicherintensive Pfadmatrix und wird durch einen Algorithmus ersetzt, der aus der berechneten Kostenfunktion die optimale Strategie extrahiert.

Einschritt Modell-prädiktive Regelung (One-Step MPC)

JOHANNESSON [88] kombiniert eine MPC-Regelung mit der DP, indem er die Kostenmatrix positionsgebunden im Fahrzeug abspeichert. Während der Fahrt werden die aktuellen Kosten in einem MPC-Regler als stationäre Zielgröße über einem Berechnungsschritt herangezogen. Damit ersetzt er die aufwendige DP Rechnung im Fahrzeug durch eine offline Berechnung der Kostenfunktion. Die Kostenfunktion beinhaltet alle Informationen über die vorausliegende Strecke und wird über den One-Step MPC auch bei von der Simulation abweichenden Realbedingungen robust geregelt.

Das One-Step MPC Prinzip kann auf die Rekonstruktion der optimalen Strategie übertragen werden. Nachdem die Kostenfunktion berechnet wurde, liegt sie im diskreten Fall als Kostenmatrix $J^M(\underline{x})$ vor. In Stufe $k = N$ wird der optimale Zustand anhand den minimalen Kosten $x_N^* = \arg \min(J_N^M(x_N))$ bestimmt. Im nächsten Schritt wird mit allen Aktionen μ_{N-1} , die als Folgezustand den optimalen Zustand x_N^* haben, eine Werteiteration durchgeführt. Die optimale Aktion μ_{N-1}^* definiert den optimalen Vorgängerzustand, indem die geringsten Schrittkosten J_k^+ bestimmt werden:

$$J_k^+(x_k) = \min_{\mu_k} \{ \xi_k(\underline{x}_k, \mu(\underline{x}_k)) + J_k^M(\underline{x}_k) \} \quad (5.27)$$

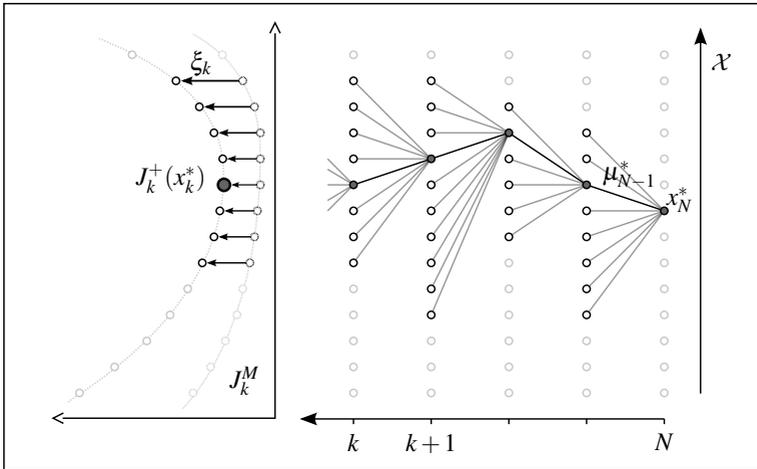


Abb. 5.29.: Schematische Darstellung des One-Step MPC Prinzips zur Pfadrückverfolgung ohne Verwendung einer Pfadmatrix

Wie in Abb. 5.29 schematisch dargestellt, werden die lokalen Schrittfolgen ξ_k mit den globalen Kosten aus der Kostenmatrix J^M addiert. Nachdem der optimale Zustand x_{N-1}^* gefunden wurde, wird von diesem aus in selber Weise fortgefahren bis zur Stufe $k = 0$. Die Information, welcher Zustand global die besten Kosten aufweist, ist in der Kostenfunktion vorhanden. Diese Information wird auf die lokale Auswahl aufaddiert und bewirkt so die optimale Auswahl der Aktion für einen Schritt nach dem MPC-Prinzip.

Der OSMPC Algorithmus 5 ist nicht auf die DDP beschränkt. Eine Anpassung auf IDP sowie auf das Boxen-Prinzip sind möglich. Bei Letzterem werden bei der Rekonstruktion Zustände statt Boxen verwendet, die idealerweise gleich wie bei der Erstellung der Kostenfunktion definiert sind.

Wird die Kostenfunktion approximiert, wird statt der Kostenmatrix die angepasste Kostenfunktion J^{fit} zur Berechnung der Schrittfolgen verwendet. Gleichung 5.27 ändert sich damit zu:

$$J_k^+(x_k) = \min_{\mu_k} \{ \xi_k(\underline{x}_k, \mu(\underline{x}_k)) + J_k^{\text{fit}}(\underline{x}_k) \} \quad (5.28)$$

Bei der IDP wird der OSMPC in jeder Iteration zur Ermittlung der optimalen Strategie ausgeführt. Dabei werden die Zustandsgrenzen jeder Iteration an den OSMPC übergeben, um die Rückwärtsrechnung im gleichen Zustandsraum auszuführen wie die Vorwärtsrechnung.

Algorithmus 5 : OSMPC One-Step Model Predictive Control**Input** : Kostenfunktion J **Output** : Optimale Strategie π^* **begin** $x_N^* = \arg \min_x J_N$ // Optimaler Zustand in N **for** $k = N - 1 : 0$ **do** $x_{\min} = x_{k+1}^* - \mu_{k,\min}(x_{k+1}^*)$ $x_{\max} = x_{k+1}^* + \mu_{k,\max}(x_{k+1}^*)$ $\mathcal{X}_k = \{x, |x_{\min} \leq x \leq x_{\max}\}$ // Einschränkung des Zustandsraums

$$J_k^+(x_k) := \min_{\mu_k} \{ \xi_k(x_k, \mu(x_k)) + J_k^M(x_k) \} \Big|_{x_k \in \mathcal{X}_k}$$

 $x_k^* := \arg \min_x J_k^+$ $\mu_k^* := \arg \min_{\mu} J_k^+$

Durch die Verwendung des OSMPC kann die Pfadmatrix und damit der benötigte Speicher reduziert werden. Der zusätzliche Rechenaufwand ist im eindimensionalen Zustandsraum zu vernachlässigen.

5.5.3. Iterative Ausführung der ADP

Bei der ADP kann der Speicher durch die approximierte Kostenfunktion und das Ersetzen der Pfadmatrix mittels OSMPC stark reduziert werden. Zur Berechnung der Kostenfunktion sind jedoch immer noch alle Zustandsübergänge über dem gesamten diskret aufgespannten Zustandsraum notwendig. Die Rechenzeit ist daher genauso lang wie bei der DDP.

Um die Rechenzeit zu reduzieren wird die iterative Änderung des Zustandsraums aus der IDP auf die ADP angewendet. Da die Basisfunktionen in jeder Distanzstufe für den Zustandsraum normiert angepasst werden, hat die Neudefinition des Zustandsraums in jeder Iteration keine Auswirkungen auf die Berechnung durch die lineare Regression. Wird in jeder Iteration die identische Anzahl an Stützstellen für das Anpassen der Basisfunktionen verwendet, liegen diese bei zunehmend kleinerem Zustandsraum näher beieinander, sodass die Güte in der Anpassung der Basisfunktionen zunimmt.

Wie bei der IDP hat die Wahl des Reduktionsfaktors γ entscheidende Auswirkung auf die Anzahl der Iterationen, bis die Kosten der Strategie zum Optimum konvergieren.

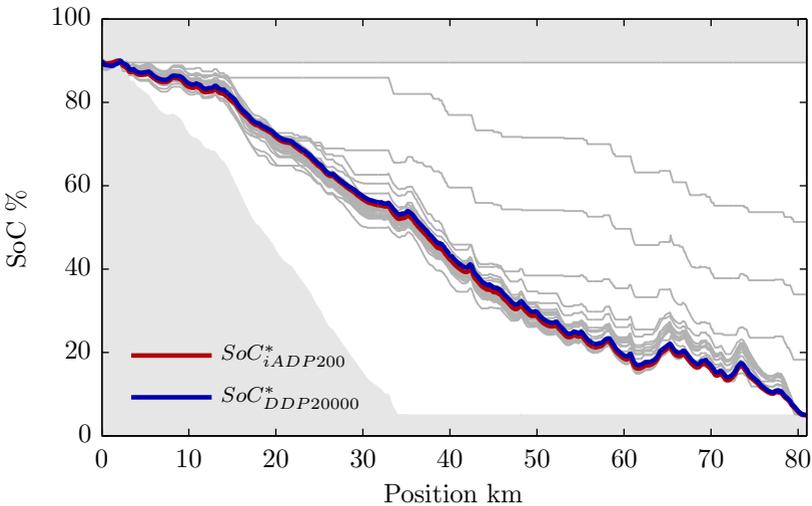


Abb. 5.30. Iterative ADP: Optimale Batterieladungsstrategie in 30 Iterationen

Ähnlich wie bei der diskreten Ausführung der IDP wird für die Berechnung der optimalen Batterieladungsstrategie der Reduktionsfaktor zwischen $\gamma = 0,9$ und $\gamma = 0,99$ gewählt.

In Abb. 5.30 sind die einzelnen Trajektorien in jeder Iteration für die Berechnung der optimalen Batterieladungsstrategie dargestellt. Die optimale Strategie ($SoC^*_{iADP200}$) nach 30 Iterationen sowie die durch die DDP ermittelte optimale Strategie ($SoC^*_{DDP20000}$) sind hervorgehoben.

Während bei der DDP Berechnung 20000 Zustände verwendet werden, um eine hinreichend genaue Auflösung des Zustandsraums zu gewährleisten, wurde die ADP mit nur 200 Zuständen, 30 Iterationen und einem Reduktionsfaktor von $\gamma = 0,9$ berechnet. Die Rechenzeit beträgt bei der ADP nur 10,22 % im Vergleich zur DDP. Bei einer Abweichung von 0,31 % in den Kosten wird der benötigte Rechenspeicher auf 0,028 % des Speicherbedarfs bei der DDP reduziert.

Bei der Untersuchung wurde der Zustandsraum am Ende des Zyklus nicht auf einen Ziel-SoC beschränkt. Dadurch nähern sich die Trajektorien in jeder Iteration von oben der optimalen Strategie an. Zum Vergleich kann bei Geschwindigkeitsstrategie und der IDP der Zustandsraum über wenig Stützstellen komplett abgedeckt werden. Die physikalischen Eigenschaften der Batterie schränken jedoch den maximalen Abstand zwischen zwei Zuständen stark ein. Damit kann der Zustandsraum für eine bestimmte Anzahl von Zuständen auch nur einen eingeschränkten Bereich aufweisen.

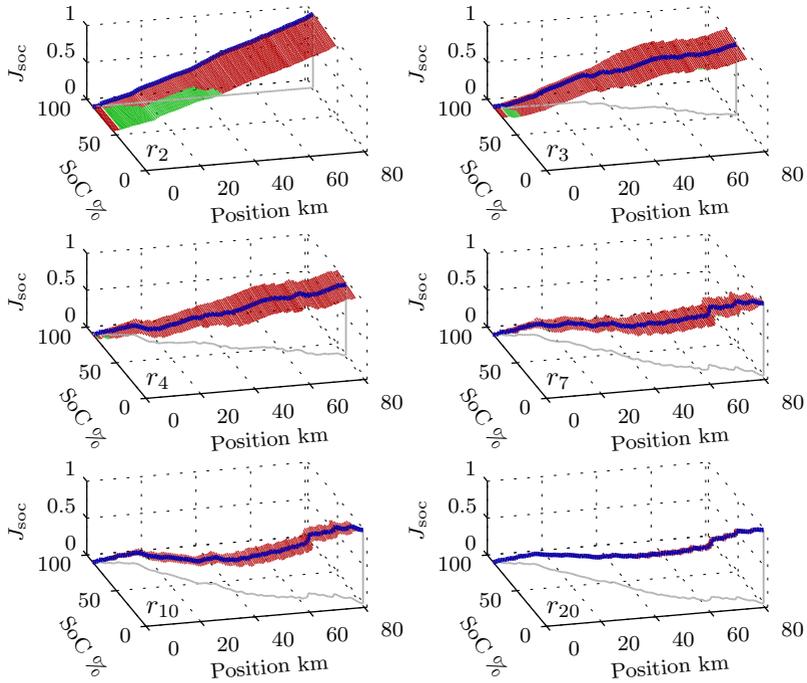


Abb. 5.31.: Iterative ADP: Die angepasste Kostenfunktion der sechs Iterationen ($r_2, r_3, r_4, r_7, r_{10}, r_{20}$) für die optimale Batterieladungsstrategie auf dem Referenzzyklus

Die iterative Verkleinerung des Zustandsraums wird mit einer Verschiebung des Suchraums um die aktuelle Trajektorie wie bei der Policy Iteration gekoppelt.

In Abb. 5.31 kann man anhand der Kostenfunktionen den Bereich sowie die Breite des Zustandsraums in ausgewählten Iterationen erkennen. Während in den ersten Iterationen nur der obere Bereich des Zustandsraums abgedeckt ist, wandert dieser bei weiteren Iterationen und zunehmender Distanz Richtung kleineren SoC-Werten. Die Breite des Zustandsraums nimmt dabei in jeder Iteration weiter ab.

Die Optimierung ist abgeschlossen, wenn der Gradient der Gesamtkosten von einer Iteration zur nächsten einen gewünschten Wert unterschreitet und die Kosten damit konvergieren.

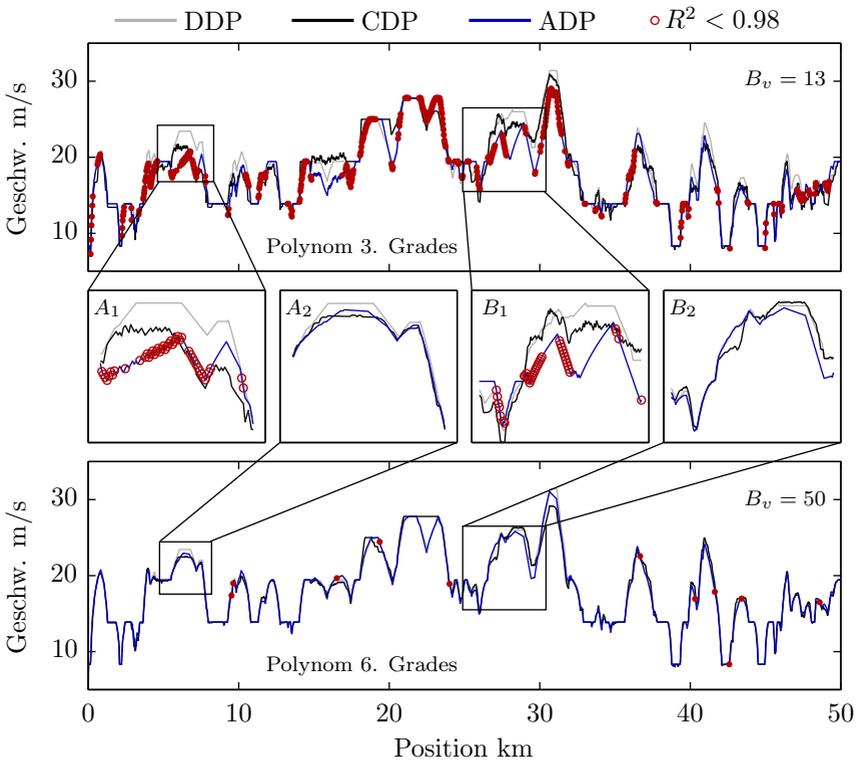


Abb. 5.32.: Die optimale Geschwindigkeitsstrategie berechnet durch unterschiedliche Methoden.

5.5.4. ADP im kontinuierlichen Zustandsraum

Wendet man die ADP auf den kontinuierlichen Zustandsraum an, werden die Basisfunktionen auf die Kosten in den Zustandsboxen angepasst. Die minimalen Kosten in jedem Schritt stellen die Stützstellen für die Regression dar und sind im Gegensatz zum diskreten Zustandsraum nicht äquidistant.

Die Basisfunktion bildet nicht nur den optimalen Zustand in einer Box ab, sondern beschreibt durch die funktionale Form den gesamten kontinuierlichen Zustandsraum. Dies hat eine glättende Wirkung der Kostenfunktion zur Folge, die einem stochastischen Rauschen bei wenigen Zustandsboxen beim Boxen-Prinzip (siehe Abschnitt 5.4.4) entgegenwirkt.

In Abb. 5.32 ist das stochastische Rauschen bei der Berechnung der DP mit $B_v = 13$ Boxen (CDP) deutlich zu erkennen, das bei einer größeren Anzahl von Boxen $B_v = 50$ reduziert werden kann.

Obwohl bei der Vorwärtsrechnung der ADP die Kosten identisch wie bei der CDP bestimmt werden, wird durch das Verwenden des OSMPC zur Pfadrückverfolgung die Strategie geglättet. Die Güte der Basisfunktionen hat damit keine Auswirkung auf die Gesamtkosten am Ende des Zyklus, da diese wie bei der CDP von einer Stufe zur nächsten aufsummiert werden. Für die Rückwärtsrechnung mit der OSMPC entscheidet die Güte der Basisfunktionen über den Verlauf der Strategie.

Die Bewertung der Strategie, die bei der DP im Allgemeinen über die Gesamtkosten am Ende des Zyklus vorgenommen wird, muss bei der ADP um eine Bewertung der Güte der Basisfunktionen und des damit verbundenen Verlaufs der Strategie erweitert werden. Das Abweichen einer Basisfunktion kann einen fehlerhaften Zustandsübergang bei der Pfadrückverfolgung verursachen, der wiederum die Strategie entscheidend ändert. In den beiden Ausschnitten A_1 und B_1 in Abb. 5.32 führen mehrere unzureichend angepasste Basisfunktionen (rot markiert) zu einer Strategiewahl, die nicht der berechneten optimalen Strategie entspricht. Ist der Grad des Polynoms der Basisfunktion zu klein oder die Anzahl der Boxen zu niedrig gewählt, nimmt die Anzahl der lokalen Fehler in der Pfadrückverfolgung zu. Werden beide Parameter erhöht, (siehe Ausschnitt A_2 und B_2 in Abb. 5.32) folgt die rekonstruierte Strategie sehr gut der optimalen Strategie. Als Referenz dient die optimale Strategie berechnet durch die DDP.

Die Güte der durch die ADP berechneten Strategie soll im Folgenden anhand globaler Gütemaße bestimmt werden, die zur Prüfung von Regressionsfunktionen herangezogen werden.

Statistische Bewertung der Kostenfunktion

Das Bestimmtheitsmaß (R^2), die F-Statistik sowie der Standardfehler stellen nach [13] globale Gütemaße dar, mit denen eine Regressionsfunktion bewertet werden kann. Die Prüfung einzelner Regressionskoeffizienten wird vernachlässigt, da es sich bei den Koeffizienten um eine mathematische Beschreibung der Kostenfunktion handelt.

Das Bestimmtheitsmaß ist definiert als Quotient aus erklärter Streuung und Gesamtstreuung. Die Residuen e_k stellen die nicht erklärte Streuung dar, wodurch das Bestimmtheitsmaß $R^2 \in [0, 1]$ wie folgt als Subtraktion vom Maximalwert berechnet wird [13]:

$$R^2 = 1 - \frac{\sum_{k=1}^K e_k^2}{\sum_{k=1}^K (y_k - \bar{y})^2} \quad (5.29)$$

K ist dabei die Anzahl der Beobachtungswerte, während die Gesamtabweichung der einzelnen Beobachtungen y_k vom Mittelwert \bar{y} bestimmt wird.

Das Bestimmtheitsmaß wird bei der ADP in jeder Stufe für jede angepasste Basisfunktion bestimmt. Dabei wird die Anzahl der Beobachtungen durch die Anzahl der

Boxen festgelegt und ist somit für jede Stufe gleich groß. Wie in Abb. 5.32 zu sehen, kann ein vermeintlich hohes Bestimmtheitsmaß von $R^2 \in [0,75 \dots 0,98]$ in einer Stufe zu einem falschen Strategieverlauf führen. Für eine Strategie nahe der optimalen Strategie reicht es nicht aus ein hohes mittleres Bestimmtheitsmaß zu erreichen. Einzelne Ausreißer sind daher zu beachten, deren Anzahl es zu reduzieren gilt.

Für eine Untersuchung der Güte der Kostenfunktion bei der ADP wird die Geschwindigkeitsstrategie für unterschiedliche Anzahlen von Boxen sowie für unterschiedliche Basisfunktionen mit Polynomen 2. bis 6. Grades berechnet. In Abb. 5.34 sind alle Bestimmtheitsmaße für eine festgelegte Anzahl von Beobachtungen (Boxen) in Form eines Box-Whisker-Plots aufgetragen. Während das untere Quartil beim Polynom 2. Grades bis auf $R^2 = 0,5$ absinkt, befinden sich diese Streuungsmaße bei den Polynomen höheren Grades bei Werten $R^2 > 0,9$. Die Ausreißer (graue Punkte) nehmen bei zunehmender Anzahl von Boxen und steigender Ordnung des Polynoms ab. Während beim Polynom 3. Grades auch bei einer größeren Anzahl von Boxen Ausreißer mit einem minimalen Bestimmtheitsmaß von $R^2 = 0,75$ vorkommen, verbessert sich die Varianz der Werte für die Basisfunktion mit einem Polynom 6. Grades auf ein minimales $R^2 = 0,98$.

F-Statistik: Das Bestimmtheitsmaß kann nur eine Aussage darüber geben, wie gut die Regressionsfunktion die beobachteten Daten wiedergibt. Um die Signifikanz des geschätzten Modells nachzuweisen und damit die geeignete Anzahl von Stichproben festzulegen, wird die F-Statistik herangezogen. Durch die Überprüfung einer Nullhypothese H_0 wird ein Zusammenhang der abhängigen und unabhängigen Variablen in der Regressionsfunktion nachgewiesen [13]. Dazu wird ein empirischer Wert F_{emp} bestimmt, der je nach gewählter Vertrauenswahrscheinlichkeit mit einem kritischen Wert F_{tab} verglichen wird. Ist der empirische Wert F_{emp} größer als der theoretische Wert aus der Tabelle F_{tab} , wird die Nullhypothese verworfen und der Zusammenhang und damit auch das Modell als signifikant erachtet. Der empirische Wert F_{emp} lässt sich aus dem Bestimmtheitsmaß berechnen:

$$F_{\text{emp}} = \frac{R^2/J}{(1-R^2)/(K-J-1)} \quad (5.30)$$

Dabei ist J die Zahl der erklärenden Variablen und damit die Ordnung der Polynome. K stellt die Anzahl der Boxen dar. Für jede Basisfunktion wird der F-Test durchgeführt. Die Güte der Kostenfunktion lässt sich durch die Anzahl der signifikanten Basisfunktionen bestimmen. Die Summe aller signifikanten Basisfunktionen normiert auf die Anzahl der Stufen N ergibt einen Index für die prozentuale Signifikanz der gesamten Kostenfunktion F_{sig} :

$$F_{\text{sig}} = \frac{\sum_{k=1}^N H_1}{N}, \quad \text{für } H_1 = \begin{cases} 1, & \text{für signifikant} & (F_{k,\text{emp}} > F_{\text{tab}}) \\ 0, & \text{für nicht signifikant} & (F_{k,\text{emp}} \leq F_{\text{tab}}) \end{cases} \quad (5.31)$$

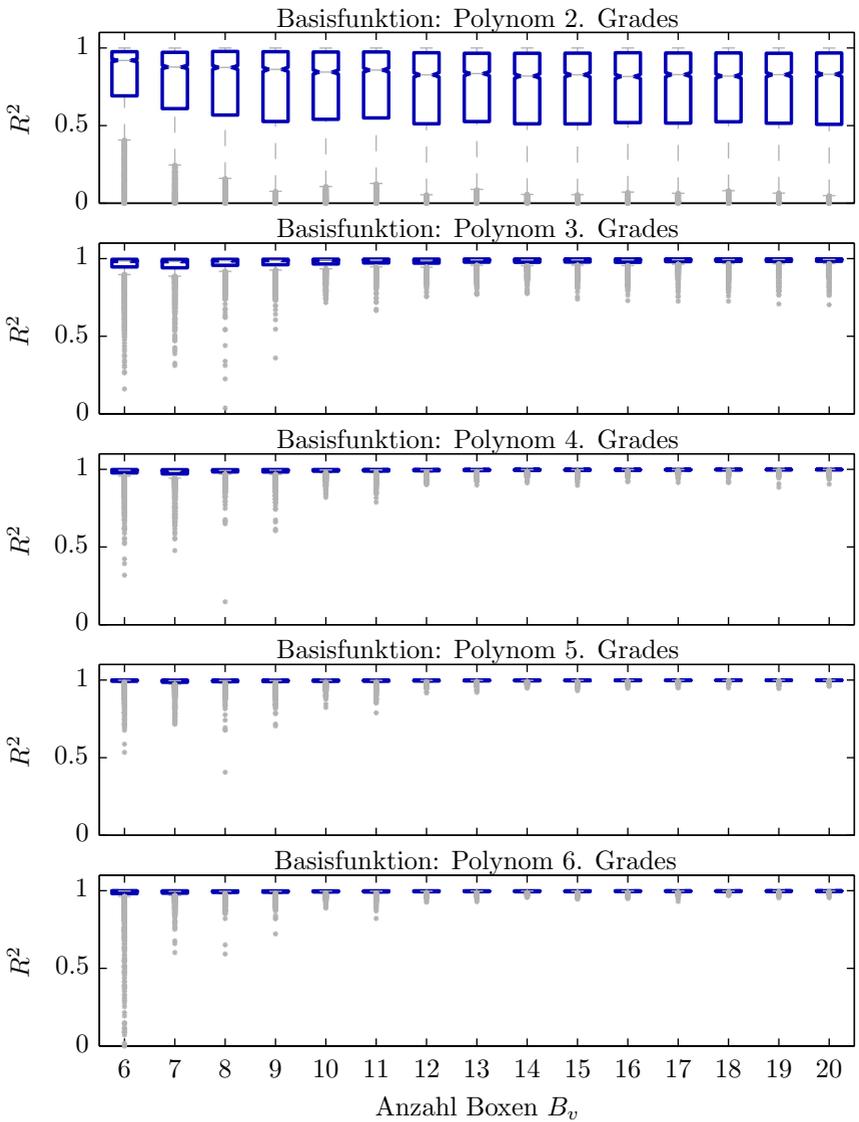


Abb. 5.33.: Die Güte der einzelnen Basisfunktionen (R^2) zur Beschreibung der Kostenfunktionen in der ADP dargestellt im Boxplot für unterschiedliche Ordnung des Polynomgrades und einer Variation der Anzahl der Zustandsboxen

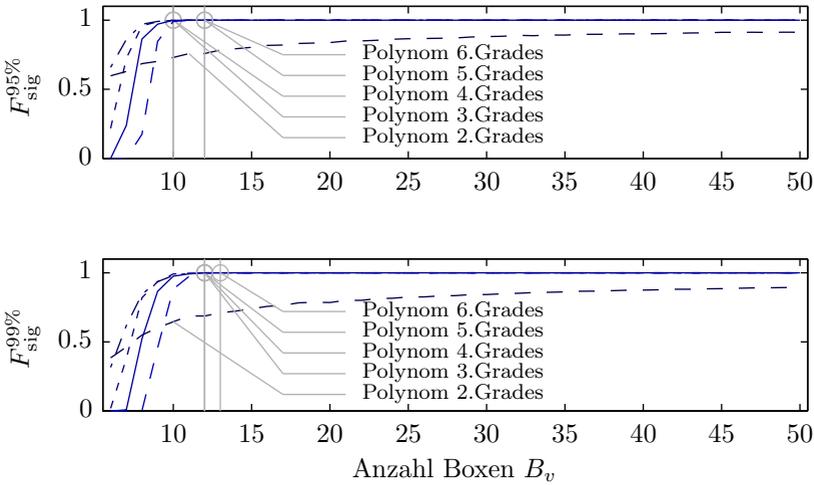


Abb. 5.34.: Signifikanz der Kostenfunktion über der Anzahl der Boxen und die Ordnung der Basisfunktion

Betrachtet man als Vertrauenswahrscheinlichkeit das 95 %-Quantil und das 99 %-Quantil der F-Verteilung, so lässt sich die Signifikanz der Kostenfunktion über der Anzahl der Boxen und mit unterschiedlicher Ordnung des Polynoms der Basisfunktion darstellen (siehe Abb. 5.34).

Während die Signifikanz der Kostenfunktion bei einem Polynom 2. Grades selbst bei $B_v = 50$ Zustandsboxen nicht erreicht wird, ist diese bei Polynomen höherer Ordnung bei $B_v > 10$ für ein Polynom 3. und 4. Ordnung sowie $B_v > 12$ für ein Polynom 5. und 6. Ordnung gegeben. Bei einer Vertrauenswahrscheinlichkeit von 99 % verschiebt sich die Grenze auf $B_v > 12$ für ein Polynom 3., 4. und 5. Ordnung und auf $B_v > 13$ für eine Basisfunktion mit 6. Ordnung.

6. Ein energie- und zeitoptimales Fahrerassistenzsystem für Hybridfahrzeuge

Auf Basis der in Kapitel 5 vorgestellten Methoden zur echtzeitfähigen Optimierung von Fahr- und Energiemanagementstrategien werden diese als Strategieoptimierung in ein Fahrerassistenzsystem für Hybridfahrzeuge integriert. Dabei werden im Sinne einer mehrstufigen Modellprädiktiven Regelung (Kapitel 4.3) die drei Stufen der Strategieoptimierung im Detail vorgestellt. Es folgt die Integration der Optimierung in die Fahrzeugarchitektur. Einzelne Module und deren Aufgabe werden vorgestellt. Die verwendete Prototyping Hardware und Software im Fahrzeug sowie in der Simulationsumgebung wird erläutert.

6.1. Strategieoptimierung

Die Strategieoptimierung beinhaltet sowohl die strategische Planung bis zum Fahrtziel als auch die steuerungstechnische Umsetzung der Sollgrößen über Schnittstellen zum Antriebsstrang. Die dafür benötigten Informationen stehen in unterschiedlich langen Zeitintervallen zur Verfügung. Die Information eines Staus in mehreren hundert Kilometern muss nicht unbedingt eine Auswirkung auf die aktuelle Regelung des Energiemanagements haben, während auf ein einscherendes Fahrzeug sofort reagiert und neu berechnet werden muss.

Wie in Abb. 6.1 schematisch dargestellt, wird die Strategieoptimierung in drei Stufen aufgeteilt, die sich im jeweiligen Prädiktionshorizont unterscheiden.

Die LONGRANGE-Strategie verarbeitet Streckendaten bis zum eingegebenen Fahrtziel. Der Prädiktionshorizont kann daher mehrere hundert Kilometer umfassen und wird als Fernhorizont bezeichnet. Die Updaterate richtet sich nach der Frequenz neu verfügbarer Informationen wie z. B. einer Routenänderung oder einer Aktualisierung der Verkehrsinformationen. Da die resultierende Strategie primär als Führungsgröße für höher frequente Stufen dient, sind nicht-deterministische Algorithmen zur Berechnung möglich. Ziel der LONGRANGE-Strategie ist die Leistungsprädiktion am Rad und an den Aggregaten sowie eine daraus resultierende Batterieladungsplanung.

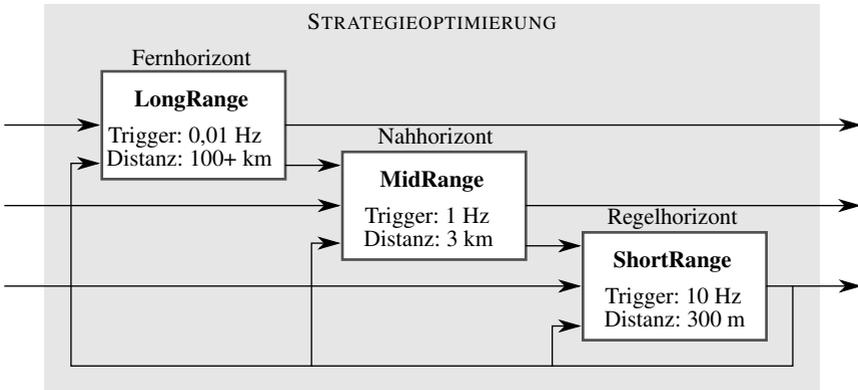


Abb. 6.1.: Dreistufige Strategieoptimierung

Bei der MIDRANGE-Strategie erstreckt sich der Prädiktionshorizont auf bis zu drei Kilometer Länge. Mit einer Updaterate von einem Hertz ist eine parallele Optimierung der Fahr- und Energiemanagementstrategie gewährleistet. Die Batterieladungsplanung aus der LONGRANGE-Strategie wird als Sollgröße am Ende des Nahhorizonts herangezogen. Fehlt diese Vorgabe, werden Strategien generiert, die nur auf diesem Nahhorizont energetisch optimal sind und auf die gesamte Strecke suboptimal sein können.

Die SHORTRANGE-Strategie repräsentiert die Längsregelung des Fahrzeugs und ersetzt damit das bestehende ACC-System. Mit einer Taktrate von 10 Hertz können aktuelle Umgebungsveränderungen in der Optimierung berücksichtigt werden. Die Strategie der MIDRANGE Optimierung wird als Vorgabe im Regelhorizont verwendet, wobei aktuelle Änderungen diese überstimmen können.

Das Zusammenspiel aller drei Strategiestufen ermöglicht eine echtzeitfähige Optimierung der energie- und zeitoptimalen Strategien über den gesamten Horizont. Informationsänderungen werden schnellstmöglich verarbeitet und verbessern so die Prädiktionsgüte der Regelung. Fallen Informationen einer Stufe aus oder ist die Berechnung noch nicht abgeschlossen, ist die unterlagerte Stufe immer in der Lage in ihrem Prädiktionshorizont ein optimales Ergebnis zu liefern.

Im Folgenden wird der Aufbau der einzelnen Strategien sowie die Wahl der Algorithmen und Fahrzeugmodelle genauer beschrieben.

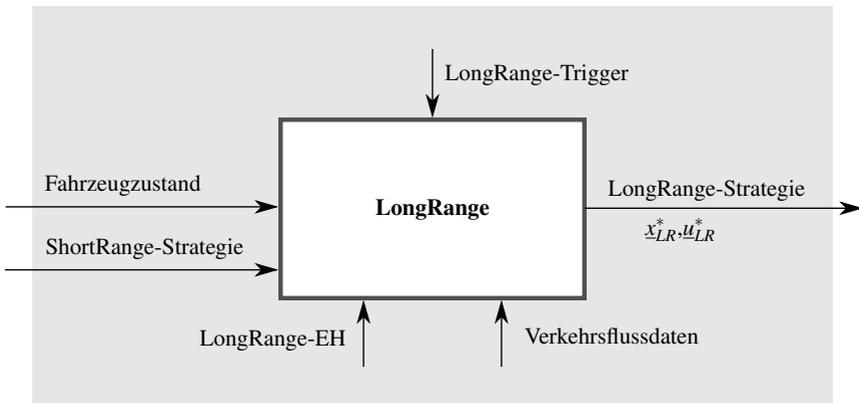


Abb. 6.2.: LONGRANGE-Strategie

6.1.1. Planung bis zum Ziel: LONGRANGE-Strategie

Die LONGRANGE-Strategie beinhaltet sowohl die Leistungsprädiktion als auch die SoC-Planung bis zum Fahrtziel. Wie in Abb. 6.2 dargestellt, wird ausgehend vom aktuellen *Fahrzeugzustand* und der *SHORTRANGE-Strategie* zyklisch eine optimale Strategie berechnet. Der *LONGRANGE-EH*⁶⁶ umfasst gesetzliche Geschwindigkeitsvorgaben sowie den Höhenverlauf entlang einer vorgegebenen oder prädizierten Route. *Verkehrsflussdaten* können über die EH-Schnittstelle oder separat hinzugefügt werden. Der *LONGRANGE-Trigger* kann sowohl zu periodischen Zyklen als auch eventbasiert ausgeführt werden, sobald neue Verkehrsinformationen vorliegen. Während die unterlagerten Stufen ohne das Wissen über ein Fahrtziel agieren können, ist eine manuelle Zieleingabe oder Routenschätzung für das LONGRANGE Modul notwendig.

Die planerische Funktion des LONGRANGE Moduls erlaubt das Verwenden nicht-deterministischer Algorithmen sowie das Aufteilen des Optimierungsproblems in eine optimale Fahrstrategie und eine daraus abgeleitete optimale Energiemanagementstrategie. Wechselwirkungen der Strategien werden vernachlässigt, um die Komplexität zu reduzieren. Die größte Herausforderung der Planung bis zum Fahrtziel ist die große Varianz der Streckenlänge des Fernhorizonts. Bei mehreren hundert Kilometern sind mehrere zehntausend Streckenstützstellen notwendig, die wiederum pro Dimension die Rechenzeit und vor allem den Speicherbedarf bestimmen. Aus diesem Grund werden zur Berechnung der LONGRANGE-Strategie Algorithmen der Approximierten Dynamischen Programmierung verwendet (siehe Abschnitt 5.5).

⁶⁶ Elektronischer Horizont siehe Abschnitt 3.5.2

Optimierungsablauf: Aus den Streckeninformationen des LONGRANGE-EH werden die Grenzen des Optimierungsraums in Form eines Fahrschlauchs definiert. Sind *Verkehrsfussdaten* vorhanden, wird die obere Grenze dieses Fahrschlauchs durch diese Informationen maßgeblich eingeschränkt. Liegen für einen Abschnitt keine oder unzureichende Verkehrsfussinformationen vor, wird auf die zulässige Höchstgeschwindigkeit zurückgegriffen. Maximale Beschleunigungen und Verzögerungen schränken den Fahrschlauch weiter ein. In diesem definierten Optimierungsraum für relevante Geschwindigkeiten findet wie in Abb. 6.3 dargestellt der erste Schritt der LONGRANGE-Strategie statt, die Optimierung der Geschwindigkeitsstrategie (V-Strategie).

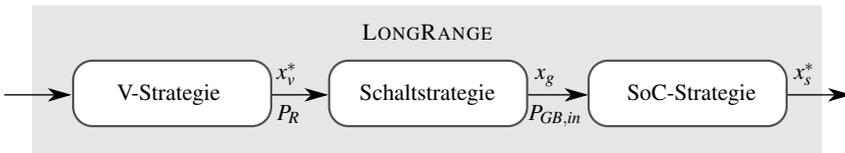


Abb. 6.3.: Serieller Optimierungsablauf der LONGRANGE-Strategie

Das Ergebnis der V-Strategie ist ein optimaler Zustandsvektor x_v^* , aus dem mit der zugehörigen Zugkraft F_x die Leistung am Rad bestimmt werden kann: $P_R = x_v^* \cdot F_x$. Es folgt die Schaltstrategie, die je nach gewähltem Gang die Leistung am Getriebeeingang $P_{GB,in}$ und damit die Gesamtleistung festlegt, die bei der nachfolgenden SoC-Strategie optimal von den Aggregaten gestellt wird.

Die Schaltstrategie bestimmt die Güte der Leistungsprädiktion an den Aggregaten maßgeblich. In der Längsführung können optimale Schaltpunkte durch Kennfelder vorgegeben werden, die durch die Vorgabe der Geschwindigkeit und auch der Gangwahl so in der SHORTRANGE-Strategie umgesetzt werden können. Für die LONGRANGE-Strategie kann diese Schaltstrategie aus der Längsregelung angelernt und in Kennfelder vereinfacht und dadurch präzifizierbar abgespeichert werden.

Wird die Leistungsprädiktion in Freifahrt (ohne Längsführung) verwendet, ist es notwendig, die im Fahrzeug verbaute Schaltstrategie möglichst zuverlässig präzifizieren zu können, auch wenn die Geschwindigkeit vom Fahrer frei gewählt wird. Diese Schaltstrategie ist meist durch eine Vielzahl von Kennfeldern und Regeln appliziert und wird an das Fahrverhalten sowie das Gaspedal dynamisch angepasst. In Abb. 6.4 ist eine Gangschaltstrategie für ein 8-Gang Automatik Getriebe abgebildet. Aus Messdaten wird ein Kennfeld erstellt, das den Gang aus Zugkraft und Geschwindigkeit festlegt. Dabei wird in der rein elektrischen Fahrt (E-Drive) eine eigene Strategie verfolgt, die nur die ersten fünf Gänge wählt. Niedrige Gänge führen bei höheren Geschwindigkeiten zu höheren Drehzahlen, die wiederum die Betriebspunkte der E-Maschinen in wirkungsgradoptimalere Bereiche verlagern.

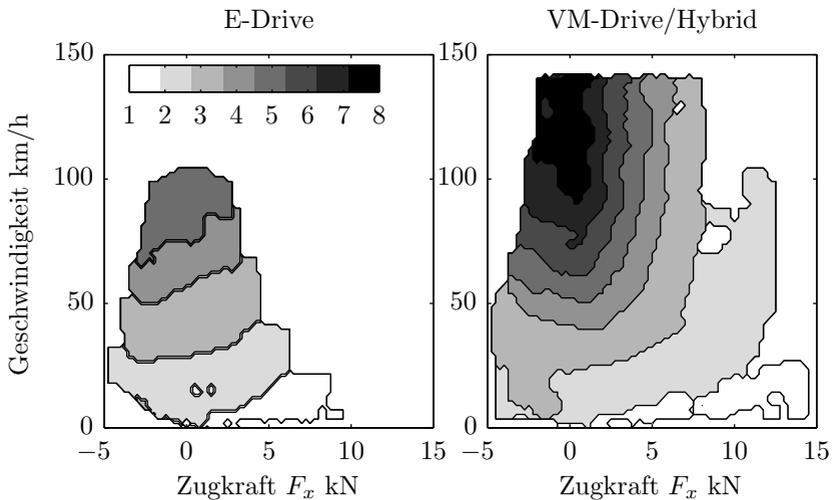


Abb. 6.4.: Gangschaltstrategie aus Messdaten ermittelt nach [177]

Die SoC-Strategie berechnet die optimale Momentenaufteilung zwischen E-Maschine und Verbrennungsmotor sowie das Rekuperations- und Bremsverhalten. Da E-Fahrt Phasen Teil des Optimierungsergebnisses sind, ist neben der Iteration der SoC Zustände eine weitere Iteration über die Hybridmodi notwendig, um die zugehörige Gangstrategie x_g auszuwählen. Vereinfacht können die Hybridmodi in zwei Gruppen unterteilt werden: Modi mit Verbrennungsmotor aus und Modi mit Verbrennungsmotor an.

6.1.2. Nahhorizont: MIDRANGE-Strategie

In Abb. 6.5 ist das MIDRANGE-Modul mit Ein- und Ausgangssignalen gezeigt. Zyklisch gesteuert wird der Prozess durch den MIDRANGE-Trigger. Die LONGRANGE-Strategie gibt die Orientierung am Ende des Nahhorizonts vor. Der aktuelle Fahrzeugzustand und die SHORTRANGE-Strategie bilden die Anfangsbedingungen für die Optimierung. Der SHORTRANGE-Electric Horizon (EH) beinhaltet alle relevanten Streckenattribute für den Nahhorizont. Die MIDRANGE-Strategie beinhaltet neben den optimalen Zustandsverläufen der Fahr- und Energiemanagementstrategie die Steuergrößen (u_{MR}^*): E-Maschinenmoment T_{EM} , Verbrennermoment T_{ICE} sowie Hybridmodus H_i . Da die alleinige Angabe der Momentenverteilung keinen eindeutigen Verlauf des SoCs festlegt, ist der Hybridmodus als dritte Steuergröße notwendig.

In der MIDRANGE-Strategie werden Fahr- und Energiemanagementstrategie parallel optimiert. Dafür ist ein mehrdimensionaler Optimierungsalgorithmus notwendig, der sowohl eine energetische, zeitliche als auch komfortable Strategie bewerten kann.

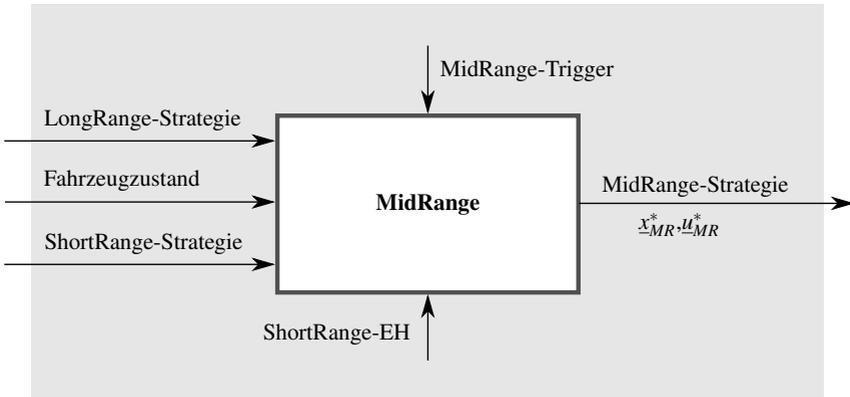


Abb. 6.5.: MIDRANGE-Strategie

Es wird die Dynamische Programmierung im kontinuierlichen Zustandsraum mit dem Boxen-Prinzip nach Abschnitt 5.4.2 verwendet.

Die Zustandsgrößen eines Hybridfahrzeugs werden abhängig von den zu bewerteten Größen gewählt. Für die zeitliche Betrachtung stellt die Geschwindigkeit in Längsrichtung eine Größe dar. Die Batterieladung ermöglicht eine energetische Betrachtung. Um dynamisches Verhalten sowie den Komfort zu bewerten, sind weitere Zustandsgrößen notwendig. Durch die Längsbeschleunigung lässt sich der Ruck bewerten. Gangschaltungen, Motorwiederstartvorgänge sowie das Wechseln der Hybridmodi erfordern das Hinzufügen weiterer Größen in den Zustandsraum. Der Zustand lässt sich somit wie folgt definieren:

$$\underline{x}_k = \begin{bmatrix} v \\ a \\ s \\ h \\ g \end{bmatrix}, \text{ für } k = 0, 1, \dots, N, \quad (6.1)$$

wobei:

- v = Längsgeschwindigkeit (kontinuierlich)
- a = Längsbeschleunigung (kontinuierlich)
- s = Batterieladezustand SoC (kontinuierlich)
- h = Hybridmodus (diskret)
- g = Gang (diskret).

Jede Zustandsgröße stellt eine Dimension im Zustandsraum dar, die entweder kontinuierlich oder diskret definiert ist und durch eine unterschiedliche Anzahl von Boxen B abgebildet wird. Da bei der DP jeder Zustandsübergang möglich sein kann, lässt sich die Komplexität der zu berechnenden Zustandsübergänge beschreiben als:

$$\mathcal{O}(N \cdot B_v^2 \cdot B_a^2 \cdot B_s^2 \cdot B_h^2 \cdot B_g^2) \quad (6.2)$$

Die Schaltstrategie kann lokal optimiert werden, wenn die Annahme getroffen wird, dass ein komfortabler Beschleunigungsverlauf einen möglichst konstanten Zugkraftverlauf voraussetzt, bei dem aus niederen Geschwindigkeiten zunächst stark beschleunigt wird und sich die Beschleunigung dann bis zum Erreichen der Zielgeschwindigkeit reduziert [175]. Durch die Bewertung der Beschleunigung und des Komforts kann somit auch indirekt eine ausreichend genaue Bewertung der Schaltstrategie erfolgen. Eine Betrachtung aller möglichen Gangwechsel ist dadurch nicht notwendig. Es werden nur noch relevante lokal optimale Gänge betrachtet, wodurch die Zustandsübergänge reduziert⁶⁷ werden können zu:

$$\mathcal{O}(N \cdot B_v \cdot B_a^2 \cdot B_s^2 \cdot B_h^2 \cdot B_g) \quad (6.3)$$

Einige Zustandsgrößen sind voneinander abhängig, sodass durch physikalische Grenzen und Modelleigenschaften eine Großzahl der Zustandsübergänge nicht möglich sind. Die Aufgabe des Optimierungsalgorithmus ist es, durch die geeignete Wahl der Boxgrenzen möglichst viele Zustandsübergänge zu gewährleisten, sodass mit wenig Boxen möglichst viele Strategien betrachtet werden können.

Der Ablauf der Optimierung hat entscheidenden Einfluss auf die Gesamtrechenzeit und soll im Folgenden detailliert vorgestellt werden.

Optimierungsablauf: Um an jedem Wegpunkt k von allen aktuellen Zuständen \underline{x}_k die möglichen Folgezustände \underline{x}_{k+1} durchzugehen, sind, wie in Algorithmus 6 verdeutlicht, zehn geschachtelte *for*-Schleifen notwendig⁶⁸. Um Rechenzeit einzusparen ist die Reihenfolge der *for*-Schleifen von Bedeutung. Die innerste Schleife wird am häufigsten ausgeführt, sodass aufwendige Berechnungen in den inneren Schleifen zu einem exponentiellen Anstieg der Rechenzeit führen und möglichst weit außen vorgenommen werden sollten. Dies gilt im Besonderen für Kennfeldzugriffe des Fahrzeugmodells sowie Berechnungen von Wurzelfunktionen und trigonometrischen Funktionen.

⁶⁷ Werden je 7 Boxen verwendet, so reduziert sich die Zahl der möglichen Zustandsübergänge bei 1000 Wegpunkten von 282.475.249.000 auf 40.353.607.000 (14,29 %)

⁶⁸ Der Optimierungskern wird für jede Iteration durchlaufen und dabei globale Grenzen um gefundene Strategien angepasst (siehe IDP Abschnitt 5.4.5)

Algorithmus 6 : MIDRANGE-Strategie: Optimierungskern**begin**Ausgangszustand \underline{x}_0 **for** $k = 1 : N - 1$ **do**

- Verarbeitung relevanter Streckendaten für k
- Festlegung globaler Grenzen für jede Dimension (Boxgrenzen)
- Aufteilung der Boxen je Dimension

for $v_k = 0 : B_v - 1$ **do****for** $a_k = 0 : B_a - 1$ **do****for** $s_k = 0 : B_s - 1$ **do****for** $h_k = 0 : B_h - 1$ **do**

- **Ausgangspunkt:** Zustandsübergang $\underline{x}_k \rightarrow \underline{x}_{k+1}$
- Einschränkung Ganggrenzen ($g_{k+1}^{\min}, g_{k+1}^{\max}$)

for $g_{k+1} = g_{k+1}^{\min} : g_{k+1}^{\max}$ **do**

- Lokal optimale Beschleunigungen (a_{k+1}^{opt})

for $h_{k+1} = 0 : B_h - 1$ **do**

- SoC Grenzen ($\text{SoC}_{k+1}^{\min}, \text{SoC}_{k+1}^{\max}$)

for $s_{k+1} = \text{SoC}_{k+1}^{\min} : \text{SoC}_{k+1}^{\max}$ **do**

- Grenzggeschwindigkeiten ($v_{k+1}^{\min}, v_{k+1}^{\max}$)

for $v_{k+1} = v_{k+1}^{\min} : v_{k+1}^{\max}$ **do**

- Grenzbeschleunigungen ($a_{k+1}^{\min}, a_{k+1}^{\max}$)

for $a_{k+1} = a_{k+1}^{\min} : a_{k+1}^{\max}$ **do**

- Berechnung Folgezustand
- Bewertung Zustandsübergang

Auswahl Endzustand \underline{x}_N **for** $k = N - 1 : 0$ **do**

└ Pfadrekonstruktion: Festlegung Strategie

In der ersten Schleife (k -Schleife) werden globale Grenzbedingungen für mögliche Zustandsübergänge und Zustände bestimmt, aus denen in jeder Dimension die Grenzen der Boxen sowie deren Aufteilung festgelegt werden. Die Auswahl, welcher aktuelle Zustand möglich ist, erfolgt im Durchlaufen der nächsten vier Schleifen (v_{k-} , a_{k-} , s_{k-} , h_{k-} - Schleifen). Die Reihenfolge dieser Schleifendurchläufe ist nicht relevant, da hier nur überprüft wird, ob ein gültiger Wert in der Kostenmatrix vorliegt und damit ein Zustandsübergang überhaupt möglich wird.

Weist die Kostenmatrix einen gültigen Wert auf, wird der aktuelle Zustand x_k berechnet (Ausgangspunkt: Zustandsübergang in Algorithmus 6). Für diesen Zustand werden aus der Schaltstrategie mögliche Gänge ausgewählt. Zur weiteren Reduktion der Rechenzeit können die Ganggrenzen (g_{k+1}^{\min} , g_{k+1}^{\max}) auf nur ein oder zwei Schaltungen zum aktuellen Gang begrenzt werden. Die Berechnung der möglichen Folgezustände in den letzten vier Schleifen (v_{k+1-} , a_{k+1-} , s_{k+1-} , h_{k+1-} - Schleifen) beinhaltet mehrmaliges und wechselseitiges Einschränken möglicher Grenzwerte und soll an einem Beispiel verdeutlicht werden.

In Abb. 6.6 ist ein schematischer Ablauf der Eingrenzung und Berechnung eines Folgezustandes dargestellt:

- ① Für einen Hybridmodus aus h_{k+1} werden die möglichen Momente der E-Maschine T_{EM} eingeschränkt (graue Box).
- ② Aus maximalem und minimalem elektrischen Moment können die Grenzen der Energien bestimmt werden, welche die Batterie laden oder entladen. Daraus resultieren maximale und minimale Batterieladungszustände (s_{k+1}^{\min} , s_{k+1}^{\max}).
- ③ Für jeden Hybridmodus wird ein optimales Drehmoment T^* über vorab berechnete Kennfelder bestimmt. Dieses gewährleistet wirkungsgradoptimale Lastpunkte im gesamten Antriebsstrang. Über die Zugkraftgleichung wird daraus eine optimale Beschleunigung a_{k+1}^* berechnet (Kreuz).
- ④ In der s_{k+1} -Schleife werden nacheinander die Boxen ausgewählt, die in den SoC-Grenzen des Hybridmodus liegen.
- ⑤ Die Grenzen einer SoC-Box beschränken die möglichen elektrischen Momente. Diese wiederum grenzen die möglichen Beschleunigungen ein sowie daraus folgende maximale und minimale Geschwindigkeiten (v_{k+1}^{\min} , v_{k+1}^{\max}).
- ⑥ In der v_{k+1} -Schleife werden nacheinander die Boxen ausgewählt, die in den Grenzen aus der s_{k+1} -Schleife liegen.
- ⑦ Aus den Box-Grenzen der Geschwindigkeiten werden maximale und minimale Beschleunigungen festgelegt (a_{k+1}^{\min} , a_{k+1}^{\max}).

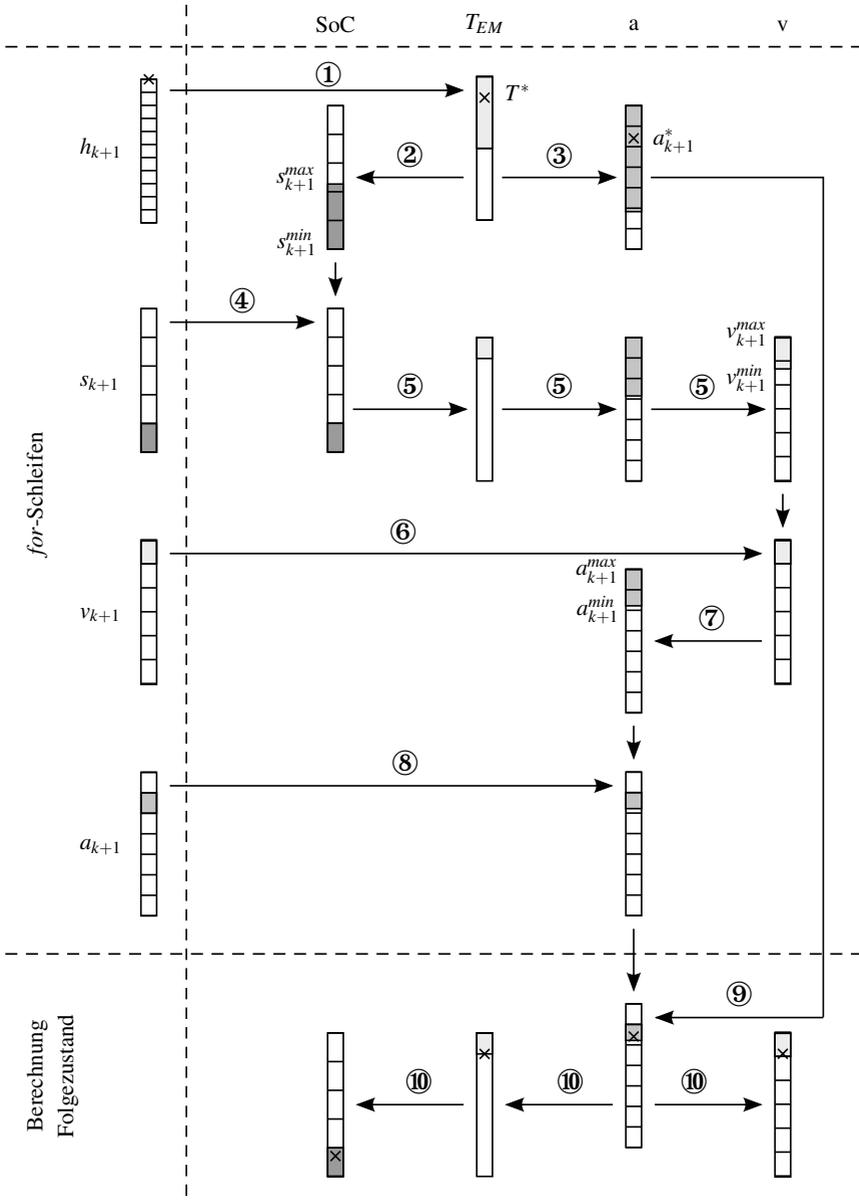


Abb. 6.6.: Auswahl des Folgezustands nach [180]

- ⑧ In der a_{k+1} -Schleife werden nacheinander die Boxen ausgewählt, die in den Grenzen aus der v_{k+1} -Schleife liegen.
- ⑨ Liegt die optimale Beschleunigung a_{k+1}^* innerhalb der Beschleunigungsbox, wird diese für den Folgezustand ausgewählt. Liegt diese außerhalb der Box, wird diejenige Boxgrenze als Beschleunigung ausgewählt, die der optimalen Beschleunigung am nächsten liegt (siehe Abschnitt 5.4.3).
- ⑩ Aus der Beschleunigung werden Werte für die Geschwindigkeit, der Momentenaufteilung sowie des SoCs des Folgezustands bestimmt. Es folgt die Berechnung der Kosten für diesen Zustandsübergang und der Vergleich mit anderen Kosten in dieser mehrdimensionalen Zustandsbox.

Die Berechnung der verschiedenen Grenzen erfordert modulare Fahrzeugmodell-Funktionen, die auf die Schleifendurchläufe angepasst sind. Das Fahrzeugmodell ist somit in die Optimierung integriert, um Rechenzeit einzusparen. Um aufwendige Berechnungen zu vermeiden werden bis zu vierdimensionale Kennfelder erstellt, die z. B. aus dem aktuellen SoC, der Bordnetzleistung, der Drehzahl und dem E-Maschinenmoment den Batteriestrom zurückgeben, sodass nur eine Interpolation auf diesem Kennfeld notwendig ist. Für diese Interpolationen werden ressourceneffiziente und schnelle Verfahren verwendet [180].

Nach der Festlegung des Zustands am Ende des Nahhorizonts ($k = N$) erfolgt die Pfadrückverfolgung, aus der ein optimaler Zustandsvektor \underline{x}_{MR}^* sowie der zugehörige optimale Steuervektor \underline{u}_{MR}^* resultieren.

6.1.3. Längsregelung: SHORTRANGE-Strategie

Die SHORTRANGE-Strategie stellt eine effiziente Längsregelung dar und unterliegt daher harten Echtzeitanforderungen. Der Prädiktionshorizont wird auf die Zykluszeit angepasst. Es sind weiterhin nur deterministische Optimierungsmethoden anwendbar, die in der vorgegebenen Zykluszeit garantiert Ergebnisse liefern. Die Optimierung erfolgt vergleichbar zur Optimierung der MIDRANGE-Strategie, wobei die Anzahl der Zustandsboxen an die erforderliche Genauigkeit der Regelung angepasst wird.

Während die Informationen auf der LONGRANGE und MIDRANGE Ebene hauptsächlich positionsabhängig vorliegen, kommen Informationen über den aktuellen Fahrzeugzustand sowie ein Großteil der Umfeldinformationen zeitabhängig an, sodass auch die Regelung zeitbasiert stattfindet. Die Aufteilung der für die Optimierung notwendigen Stützstellen in Zeitintervalle statt Distanzschritten ist daher bei der SHORTRANGE Optimierung sinnvoll.

Die Ein- und Ausgangssignale des SHORTRANGE-Moduls sind in Abb. 6.7 abgebildet. Neben den Streckendaten aus dem *Short-Range-EH* fließen weitere geschwindigkeitsbeschränkende Informationen aus der Umfeldsensorik ein.

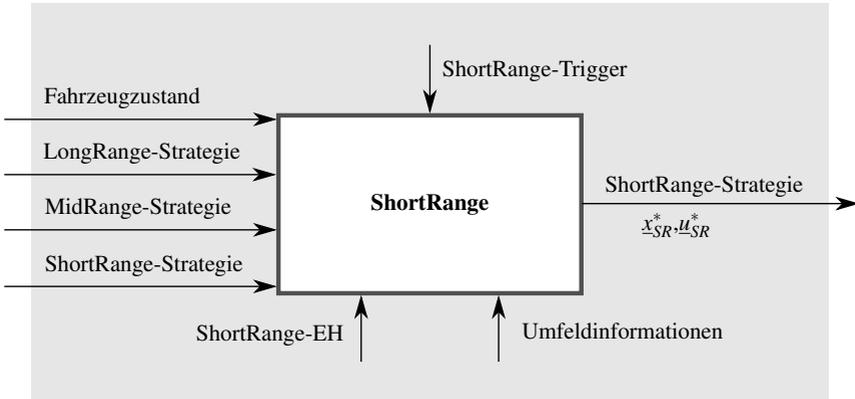


Abb. 6.7.: SHORTRANGE-Strategie

Eine entscheidende Größe sind hierbei relevante Verkehrsteilnehmer, die die geplante Geschwindigkeitstrajektorie des Ego-Fahrzeugs unterschreiten.

Die für die Regelung relevanten Größen des Fahrzeugzustands sind:

- Aktuelle Geschwindigkeit v_{ist}
- Aktuelle Beschleunigung a_{ist}
- Aktuelle Batterieladung soc_{ist}
- Aktuell eingelegter Gang g_{ist}
- Aktueller Betriebszustand des Verbrennungsmotors ω_{ist}
- Aktuelle Motordrehzahl ω_3

Die Strategien der überlagerten Stufen geben die Sollgrößen des prädierten Fahrzeugzustands am Ende des Regelungshorizonts vor. Verändert sich die aktuelle Verkehrssituation, indem z. B. ein Fahrzeug einschert, entscheidet die unterlagerte Stufe auf Basis der aktuellen Informationen unabhängig von der bereits berechneten Strategie aus der überlagerten Stufe (siehe Abschnitt 4.3). Die SHORTRANGE-Strategie wird in der Regelung direkt zurückgeführt, um Fehler abzuschätzen, die durch Modellabweichungen entstehen. Dabei wird die berechnete Beschleunigung a_{model} mit der aktuellen Beschleunigung des Fahrzeugs a_{ist} verglichen und aus der aufsummierten Differenz eine Zugkraft F_{korr} berechnet, die für eine Korrektur benötigt wird [175]:

$$F_{\text{korr}} = \int \frac{G}{m_{\text{veh}}} \cdot (a_{\text{model}} - a_{\text{ist}}) \cdot dt \quad (6.4)$$

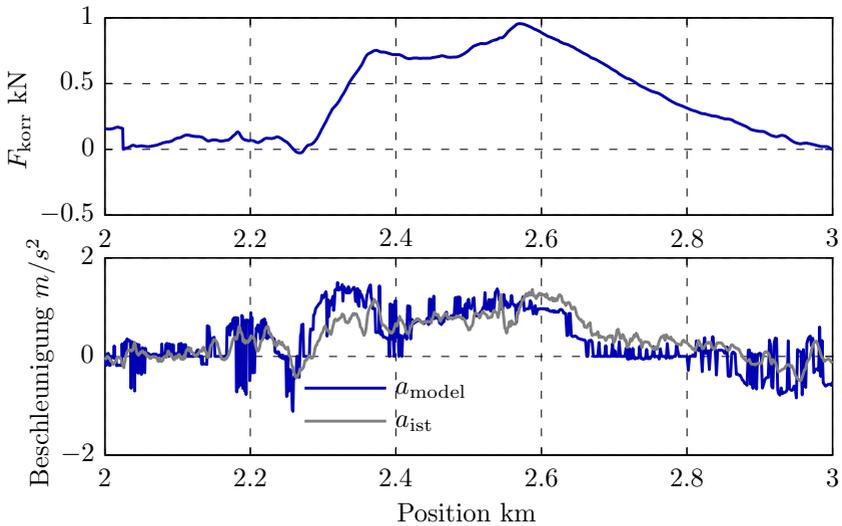


Abb. 6.8.: SHORTRANGE-Strategie: Korrektur des Zugkraftfehlers in einem Ausschnitt aus einer realen Messfahrt [175]

Dabei ist G ein Faktor, mit dem die Zugkraftabweichung im Sinne eines integralen Reglers die Modellannahmen korrigiert. Dieser Faktor wird so appliziert, dass eine möglichst schnelle Reduktion des Zugkraftfehlers erfolgt. In Abb. 6.8 sind die beiden Beschleunigungen a_{model} und a_{ist} sowie die Zugkraftkorrektur F_{korr} aus einer realen Messfahrt abgebildet. Die Regelabweichung in der Zugkraft hat mehrere Gründe. Neben einer Modellgenauigkeit in der Fahrzeuglängsführung sowie den Fahrzeugparametern (z. B. Gewicht) kann der Fahrwiderstand auch durch fehlende oder falsche Angaben in der digitalen Karte (z. B. Steigung) abweichen. Aktuelle Windböen sind durch die verbaute Sensorik weder mess- noch präzisiertbar und selbst die vorhandene Sensorik sowie die Signalverarbeitung auf dem CAN bieten weitere Fehlerquellen. Die Zugkraftkorrektur in der SHORTRANGE-Strategie ist deshalb für eine Verbesserung der Regelgüte erforderlich.

Der Steuervektor $u_{\text{§R}}$ am Ausgang der SHORTRANGE-Strategie setzt sich aus folgenden Signalen zusammen [175]:

- Gefordertes Gesamtantriebsmoment $T_{\text{ges,soll}}$
- Elektrischer Anteil am Gesamtantriebsmoment $T_{\text{EM,soll}}$
- Geforderter Gang g_{soll}
- Gefordertes An- und Abkoppeln des Verbrennungsmotors o_{soll}

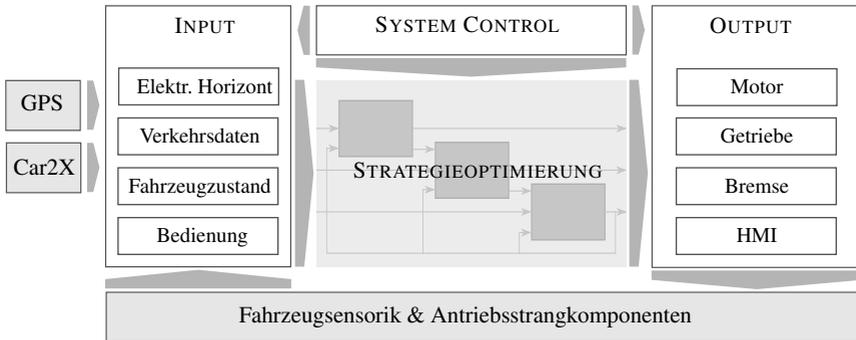


Abb. 6.9.: Schematische Darstellung des Gesamtsystems

- Modellschätzung der Beschleunigung a_{model}

6.2. Integration in die Fahrzeugarchitektur

Das Fahrerassistenzsystem und dessen Komponenten sind in die Softwarearchitektur des Fahrzeugs integriert. Da die Strategieoptimierung sowohl Planung als auch Regelung vereint, stellt diese das zentrale Modul des Gesamtsystems dar (siehe Abb. 6.9). Die einzelnen Komponenten werden nachfolgend genauer beschrieben.

6.2.1. Sensorik

Die verwendete Sensorik umfasst zum einen serienmäßig verbaute Fahrzeugsensorik, deren Signale über den CAN-Bus oder separate Entwicklungsschnittstellen kommunizieren. Weiterhin wurde das System durch einen extern angebrachten GPS-Empfänger sowie eine Internetverbindung (Car2X) ergänzt.

CAN: Unterschiedliche Steuergeräte verarbeiten Sensordaten und stellen diese teilweise durch Modelle und Filter nachbearbeitet auf dem CAN zur Verfügung. Wichtige verbaute Sensoren sind z. B. der Drehzahlmesser (Motorsteuergerät), Raddrehzahlmesser und Beschleunigungssensor (ESP) sowie der gemessene Strom an der Hochvoltbatterie (Batteriemanagement).

Radar und Video: Die Versuchsträger sind mit einem ACC Fernbereichsradarsensor ausgerüstet. Der Frequenzbereich der Radarwellen beträgt zwischen 76 und 77 GHz und ermöglicht das Erfassen von Objekten bis zu einer Entfernung von 250 Metern

bei einem horizontalen Öffnungswinkel von 30°. Es können bis zu 32 Objekte bei Relativgeschwindigkeiten zwischen -270 km/h und +216 km/h detektiert werden [26]. Die Zuweisung relevanter Objekte auf die Spur erfolgt im ACC Sensor.

Das Radarsystem wird durch eine Multi-Purpose-Camera ergänzt, die neben der Spur auch Schilder erkennt und mit in der Navigation vorhandenen Kartendaten abgleicht.

GPS: Der GPS-Empfänger besitzt einen U-blox 6 GPS SuperSense® Hochleistungschip mit aktiver Antenne. Die Positionsgenauigkeit entspricht 2,5 m und kann durch ein satellitenbasiertes Ergänzungssystem (SBAS) auf 2 m präzisiert werden. Die Updaterate beträgt bis zu 5 Hz und es können bis zu 50 Satelliten gleichzeitig verarbeitet werden [168]. Bei Ausfall des GPS Signals in Tunneln oder durch Abschattung in eng bebautem Gebiet wird auf interne Fahrzeugsensorik zurückgegriffen⁶⁹.

Car2X: Für den Empfang von aktuellen Verkehrsdaten ist eine Internetverbindung notwendig. Dabei wird über UMTS⁷⁰ eine Verbindung über das Mobilfunknetz zum Backend aufgebaut. Dieses Backend ermöglicht das Abrufen von Verkehrsinformationen für eine gewünschte Route. Eine Kommunikation zwischen unterschiedlichen Fahrzeugen (C2C) ist über diese Verbindung möglich. Die Stabilität des Funknetzes ist gerade in ländlichem Gebiet nicht immer gewährleistet, sodass eine Robustheit der Weiterverarbeitung der Signale auf Systemseite gewährleistet sein muss.

6.2.2. Modul: SYSTEM CONTROL

Koordinative Aufgaben sowohl zyklischer Art als auch in Form von Events laufen im Modul SYSTEM CONTROL zusammen. Hier werden die einzelnen Trigger der Systemoptimierung (LONGRANGE-Trigger, MIDRANGE-Trigger und SHORTRANGE-Trigger) gesetzt. Des Weiteren werden Statusinformationen der einzelnen Stufen der Systemoptimierung überwacht um Berechnungen bei fehlenden oder fehlerhaften Strategien neu anzustoßen.

Bedieninformationen des Fahrers werden in SYSTEM CONTROL interpretiert. Ändert z. B. der Fahrer seine Wunschgeschwindigkeit, führt dies zu einer Neuberechnung der Strategien. Liegen keine ausreichenden Informationen über Position oder gewünschter Route vor, werden nur mögliche Berechnungen durchgeführt oder eine Aktivierung des Systems verweigert. Der Systemstatus wird dem Fahrer über differenzierte Meldungen angezeigt.

⁶⁹ Dead Reckoning: Schätzung von Position und Orientierung

⁷⁰ Universal Mobile Telecommunications System: Mobilfunkstandard der dritten Generation (3G)

6.2.3. Modul: INPUT

Die für die Systemoptimierung benötigten Eingangssignale werden im INPUT Modul in verschiedenen Komponenten akquiriert. Relevante Signale werden aus verschiedenen CAN-Botschaften eingelesen und gegebenenfalls in Filtern weiter verarbeitet. INPUT beinhaltet neben mehreren CAN Schnittstellen digitale Schnittstellen zu oben genannter Sensorik. Wichtige Komponenten werden im Detail vorgestellt:

Elektronischer Horizont (EH): Für jede Prädiktion, die über die Sensorreichweite hinausgeht, sind Streckeninformationen erforderlich. Der EH stellt eine Struktur dar, die relevante Streckenattribute in kompakter Form beinhaltet. Diese wird zyklisch erneuert, indem zurückliegende Streckenteile verworfen und neue Komponenten am Ende des aktuellen Horizonts angefügt werden. Dabei werden Informationen, die in Graphenform in einer Karte abgespeichert sind, in Vektorform umgewandelt. Der dynamische Ausgangspunkt des EH stellt dabei immer die aktuelle Position des Fahrzeugs dar, die über das GPS bestimmt wird. In Abb. 6.10 ist der Aufbau des EH dargestellt.

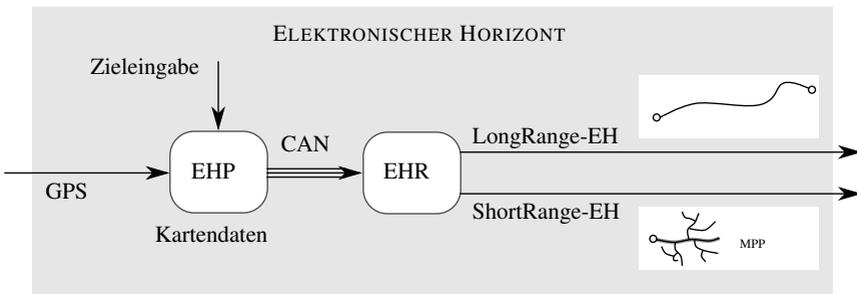


Abb. 6.10.: Schematischer Aufbau des Elektronischen Horizonts

Die aktuelle Fahrzeugposition wird der Navigation (EHP) übermittelt, die die vorausliegende Kartenattribute komprimiert über den CAN-Bus an ein Modul zur Rekonstruktion der Daten (EHR) schickt. Liegt eine Zieleingabe vor, sind sowohl der LONGRANGE-EH als auch der SHORTRANGE-EH im System verfügbar. Ohne Zieleingabe ist nur der SHORTRANGE-EH verfügbar, wobei der Horizont sich nach dem wahrscheinlichsten Pfad (MPP⁷¹) aufbaut. Während der LONGRANGE-EH nur Streckenattribute entlang der Route liefert, beinhaltet der SHORTRANGE-EH auch Attribute für Nebenpfade.

⁷¹ engl. Most Propable Path

Verkehrsdaten: Der EH stellt nur statische Kartenattribute zur Verfügung, die über eine Car2X Schnittstelle mit aktuellen Verkehrsflussdaten⁷² (TFD) ergänzt werden. Dabei wird wie in Abb. 6.11 dargestellt über das Mobilfunknetz eine Verbindung zu einem Backend eines Datenlieferanten aufgebaut.

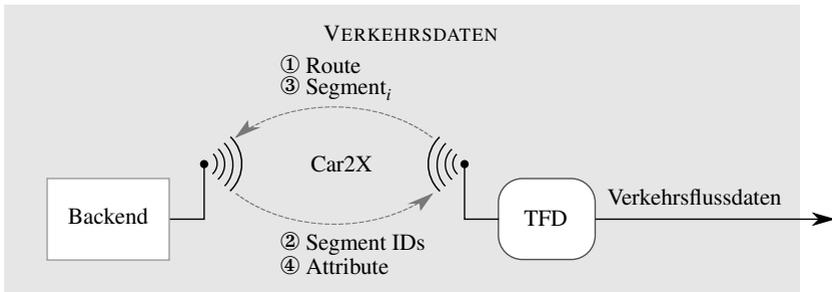


Abb. 6.11.: Schnittstelle für aktuelle Verkehrsdaten

Die Abfrage der Informationen erfolgt über eine HTTP- basierte API⁷³. Der Ablauf gliedert sich wie folgt: Im ersten Schritt ① wird die geplante Route an das Backend übermittelt. Relevante Segmente entlang der Route werden in Form von IDs zurück-gesendet ②. Für jedes Segment i werden Verkehrsdaten ③ angefordert. Das Backend sendet angefragte Attribute ④ für jedes Segment. Diese Attribute enthalten historische, durchschnittliche und aktuelle Verkehrsflussgeschwindigkeiten sowie einen Index für den aktuellen Staupegel auf dem angefragten Segment. Da sich die Segmente entlang einer Route in der Fahrzeit nicht ändern, können bei einem Update der Daten Schritt ① und ② übersprungen werden. Erst bei einer Routenänderung oder einer Abweichung von der Route müssen die Segment IDs neu abgefragt werden.

Die Segmente entlang der Route passen nicht auf die Segmente des EHs, da die zugrunde liegenden Rohkarten nicht identisch sind und sowohl beim EH als auch bei den Segmenten aus dem Backend Komprimierungen für die Übertragung vorgenommen werden. Über ein Map-Matching werden die Segmente aus beiden Datenquellen aufeinander abgeglichen sowie die für den aktuellen EH relevanten Bereiche der Systemoptimierung bereitgestellt. Ein Update erfolgt zyklisch.

Fahrzeugzustand: Um den aktuellen Zustand des Fahrzeugs zu bestimmen, werden Informationen aus den CAN-Signalen durch unterschiedliche Filter nachbearbeitet. Dabei wird Rauschen von Sensorrohdaten unterdrückt oder geglättet.

⁷² engl. Traffic Flow Data

⁷³ Programmierschnittstelle engl. Application Programming Interface

Effekte, die durch die Kommunikation über den CAN entstehen (Totzeiten, Diskretisierungen, Quantisierungen, ...) werden reduziert.

Ein Beobachter ermöglicht die Berechnung relevanter, jedoch nicht messbarer Größen. Dabei wird das Fahrzeugmodell mit vorhandenen Messgrößen verknüpft. So können zum Beispiel Verlustmomente für den aktuell eingelegten Gang aus Kennfeldern des Fahrzeugmodells bestimmt werden, die wiederum auf dem Prüfstand vermessen wurden.

Der Fahrzeugzustand stellt damit eine Struktur dar, aus der die einzelnen Stufen der Systemoptimierung die Ausgangsbedingungen der Prädiktion festlegen.

Bedienung: Die Bedienung des Systems erfolgt für den Fahrer über den serienmäßig verbauten Lenkstockhebel für das ACC. Das Bedienverhalten lehnt sich stark an dem eines ACC-Systems an. Dabei sollen durch eine einfache Bedingung ein schnelles Lernverhalten des Fahrers erreicht sowie Ablenkungen im Straßenverkehr vermieden werden.

Neben dem Ein- und Ausschalten des Systems kann der Fahrer die Längsregelung aus dem Standby aktivieren sowie über die Wippe zum Einstellen des zeitlichen Abstands zum vorausfahrenden Fahrzeug die gewünschte Dynamik in drei Stufen einstellen. Durch das Betätigen der Bremse bzw. des Gaspedals wird die Längsregelung abgebrochen bzw. übersteuert, sodass der Fahrer jederzeit eingreifen und übernehmen kann.

Die Vorgabe einer Route erfolgt über die Navigation die im Versuchsträger einen Teil des Gesamtsystems darstellt. Die Zieleingabe sowie die Auswahl einer abgespeicherten Route ist über eine grafische Benutzeroberfläche⁷⁴ (GUI) möglich.

6.2.4. Modul: OUTPUT

Die Steuergrößen der berechneten Strategien werden im Modul OUTPUT in die Strukturen der jeweiligen CAN-Botschaften eingepasst. Dabei ist nach einer Überprüfung der Validität der SYSTEM CONTROL eine Freigabe der Signale möglich. Hierbei werden Signale an die Steuergeräte der einzelnen Komponenten des Antriebsstrangs übermittelt. Die Schnittstelle des jeweiligen Signals kann einzeln aktiviert werden. Bei aktiver Längsführung wird dem Motorsteuergerät die Steuergrößen der Energiemanagementstrategie übergeben. Dem Getriebesteuergerät sowie dem Bremsensteuergerät werden Vorgaben aus der Fahrstrategie übermittelt.

Schnittstelle Hybridsteuerung: Eine direkte Vorgabe der optimalen Energiemanagementstrategie (Hybridmodus, Drehmoment der E-Maschine) ist im Versuchsfahrzeug aus Sicherheitsgründen nicht möglich.

⁷⁴ engl. Graphical User Interface

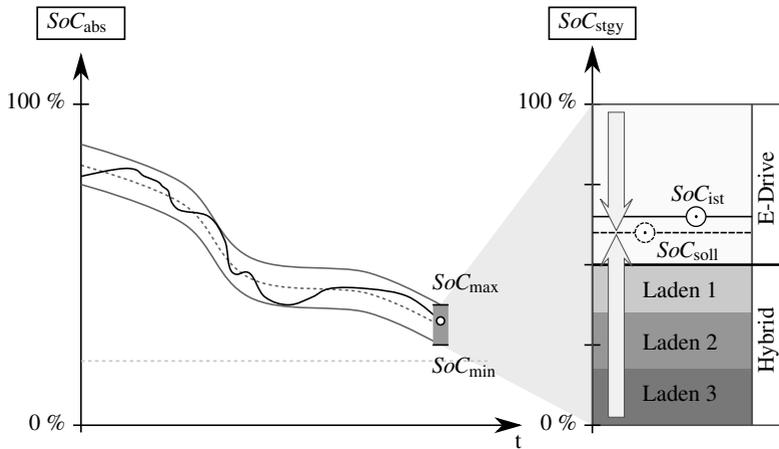


Abb. 6.12.: Schnittstelle der Hybridsteuerung zur Basisstrategie

Die vorhandene Schnittstelle ermöglicht ein Steuern des SoC-Verlaufs durch Anpassung von Grenzwerten (SoC_{max} und SoC_{min}) in der Basisstrategie über eine positionsabhängige Zielvorgabe SoC_{soll} . In Abb. 6.12 ist die Steuerung der Energiemanagementstrategie dargestellt. Wie in Abschnitt 3.2.1 beschrieben, ist die Basisstrategie SoC_{stgy} in einem relativen SoC-Fenster definiert. Die Hybridmodi in diesem Fenster sind wiederum prozentual aufgeteilt. Bei einem $SoC_{stgy} < 50\%$ wird im Betriebsmodus *Hybrid* nachgeladen. Das Nachladeverhalten wird in drei Stufen mit unterschiedlichen Ladestärken kategorisiert und basiert auf wirkungsgradoptimalen Kennfeldern. Bei einem $SoC_{stgy} \geq 50\%$ wird in den Betriebsmodus *E-Drive* gewechselt. Das maximale elektrische Moment der E-Maschine ist in diesem Bereich abrufbar. Um ein ständiges Umschalten zwischen Laden und elektrischem Fahren (Entladen) zu vermeiden wird eine Hysterese verwendet, die ein Laden bis zum Ziel-SoC (SoC_{soll}) bewirkt und ein elektrisches Entladen auch unterhalb dieser Vorgabe erlaubt.

Diese Schnittstelle schränkt die Regelung der Energiemanagementstrategien stark ein und wird in Abschnitt 7.2.4 für Messfahrten im Versuchsfahrzeug verwendet. Motorstart- und Stoppvorgänge sind bei einem SoC von weniger als 20 % aufgrund der Basisstrategie nicht mehr möglich. Des Weiteren kann das elektrische Moment, das maßgeblich die Batterieladung und Entladung bestimmt, nicht vorgegeben werden, da nur zwischen Kennfeldern der Basisstrategie umgeschaltet wird. Die Vorgabe der Betriebsmodi stellt damit eine Mehrpunktregelung dar, wodurch das gesamte Potenzial der Energiemanagementstrategie nicht genutzt werden kann.

6.2.5. Rapid Prototyping

Das Gesamtsystem wurde im Rahmen von Rapid Prototyping umgesetzt, wobei im Verlauf des Projekts ein Wechsel der Zielhardware stattfand.

MicroAutoBox: Für erste Echtzeituntersuchungen und Regelungsabstimmungen wurde eine MICROAUTOBOX II mit einem IBM POWERPC Prozessor und einer Taktfrequenz von 900 MHz und 16 GB Hauptspeicher verwendet. Vorteil dieses Prototypensteuergeräts ist das Echtzeitbetriebssystem, das eine sichere und robuste Kommunikation der Regelung mit dem CAN-Bus gewährleistet. Das Kompilieren eines neuen Softwarestandes über MATLAB/SIMULINK und die Generierung des Maschinencodes stellt einen zeitintensiven Prozess dar, womit schnelle Änderungen im Fahrzeug nur begrenzt umsetzbar sind.

Fahrzeug PC: Im Laufe des Projekts wurde die MICROAUTOBOX durch einen performanten Fahrzeug PC ersetzt. Der Fahrzeug PC verfügt über einen 2,3 GHz i7-3610 QE Prozessor mit 8 GB Arbeitsspeicher. Die Steuersignale der Regelung werden über ein CAN-Gateway dem Fahrzeug zur Verfügung gestellt. Dieses Gateway überwacht die Signale am Ausgang des Systems und deaktiviert bei Bedarf die Schnittstelle zum CAN. Dadurch ist ein Kompilieren und Debuggen der Software auch während einer Messung problemlos möglich. Weitere Vorteile des Fahrzeug-PCs sind die einfache Anbindung weiterer digitaler Schnittstellen (Navigation, Car2X) sowie eine direkte Visualisierung von Entwicklungsgrößen und HMI-Konzepten in nur einem System.

6.3. Simulationsumgebung

Alle Algorithmen der Strategieoptimierung sind in C-Code geschrieben, um maximale Performance bei möglichst niedrigem Speicherbedarf zu ermöglichen. Dadurch ist ein Einbetten dieser Module in unterschiedliche Softwareumgebungen möglich. Für die MICROAUTOBOX kann der C-Code als eingebetteter Code in die SIMULINK Umgebung integriert werden. Auf dem Fahrzeug PC werden die einzelnen C-Module in die Entwicklungssoftware ADTF⁷⁵ integriert:

ADTF: Die plattformunabhängige Softwareumgebung ADTF ist in C++ geschrieben und ermöglicht ein effizientes Implementieren neuer Fahrzeugfunktionen. ADTF kann Daten aus unterschiedlichen Quellen sammeln und synchronisieren und ermöglicht so Datenaufzeichnung, Echtzeitwiedergabe und Visualisierung in einer Umgebung [105]. Der modulare Aufbau ermöglicht es, den gleichen Systemstand sowohl im Fahrzeug, auf dem Fahrzeug PC, als auch offline am Arbeitsplatz zu verwenden.

⁷⁵ Automotive Data and Time-Triggered Framework

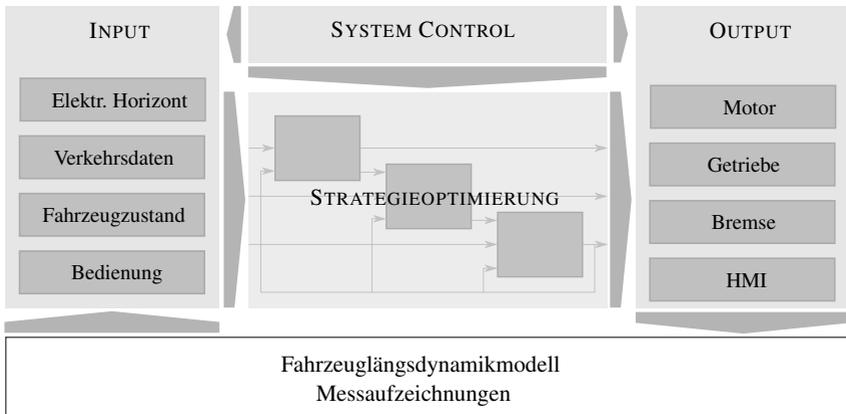


Abb. 6.13.: Aufbau der Simulationsumgebung

Für die Simulation können sowohl aufgezeichnete Messungen herangezogen werden als auch durch ein Längsdynamikmodell die Eingangssignale für die Strategieoptimierung bereitgestellt werden. In Abb. 6.13 ist der Simulationsaufbau dargestellt. Das Fahrzeugverhalten wird durch Modelle oder Aufzeichnungen simuliert. Das Gesamtsystem sowie einzelne Teilsysteme können auf Basis dieser simulierten Eingangsgrößen weiterentwickelt und validiert werden.

6.3.1. Systemverhalten

Damit eine Regelung im Fahrzeug möglich ist, sind einzelne Komponenten der Strategieoptimierung einer harten Echtzeitfähigkeit unterworfen. SYSTEM CONTROL überprüft die Rechenzeiten der einzelnen Stufen. Dabei muss bei der SHORTRANGE-Strategie wie auch der MIDRANGE-Strategie nach einer deterministischen Zeit ein Ergebnis vorliegen. Liegt im Zyklus von 50 ms keine neue SHORTRANGE-Strategie vor, muss die Regelung deaktiviert werden. Fehlen am Ende eines Regelhorizonts die Vorgaben aus der MIDRANGE-Strategie, ist eine Regelung weiterhin möglich. Ein effizientes und vorausschauendes Systemverhalten ist jedoch nicht mehr gewährleistet. Da die Berechnung der LONGRANGE-Strategie nicht-deterministisch ausgeführt wird, führt ein Fehlen der Strategie nicht zur Deaktivierung des Systems. Die Effizienz des Gesamtsystems wird aufgrund der fehlenden Vorausschau lediglich eingeschränkt.

Die Echtzeitfähigkeit des Systems wird im Folgenden am Laufzeitverhalten der SHORTRANGE-Strategie und der MIDRANGE-Strategie gezeigt.

Laufzeitverhalten

Die Berechnungen zur Laufzeitmessung erfolgen auf dem Echtzeitprozessor der MICROAUTOBOX. Das Programm arbeitet auf einer Basiszykluszeit von 10 ms. In diesem Zyklus werden alle Schnittstellen bedient und überwachende Funktionen ausgeführt. Durch ein Überschreiten dieser Zeit kann die Kommunikation mit dem CAN-Bus und anderen Schnittstellen nicht mehr gewährleistet werden, wodurch die Ausführung der Berechnungen unterbrochen und ein Fehler ausgelöst wird [175].

Die SHORTRANGE-Strategie wird über einen Software-Interrupt mit hoher Priorisierung ausgeführt.

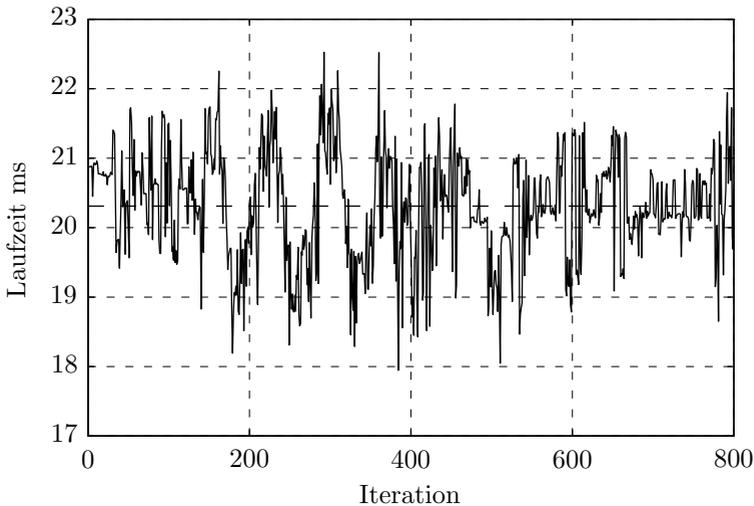


Abb. 6.14.: Laufzeitverhalten der SHORTRANGE-Strategie in der Simulation [175]

In Abb. 6.14 sind die Laufzeiten der SHORTRANGE-Strategie für 800 aufeinanderfolgende Berechnungen bei einer simulierten Fahrt dargestellt. Die durchschnittliche Berechnungszeit liegt bei 20,3 ms mit einer Varianz von 2,5 ms. Diese Schwankungen sind durch die Ausführungen der höher priorisierten Kommunikation der Schnittstellen zu erklären. Um eine echtzeitfähige Regelung zu gewährleisten, müssen nach 50 ms optimale Steuergrößen vorliegen. Im Fahrzeug kommen weitere Berechnungen des INPUT Moduls hinzu, sodass ein ausreichend großer Abstand zur vorgegebenen Zykluszeit von 50 ms notwendig ist.

Die MIDRANGE-Strategie unterliegt keinen harten Echtzeitanforderungen, da der Nahhorizont und damit auch die Berechnung stark schwanken können.

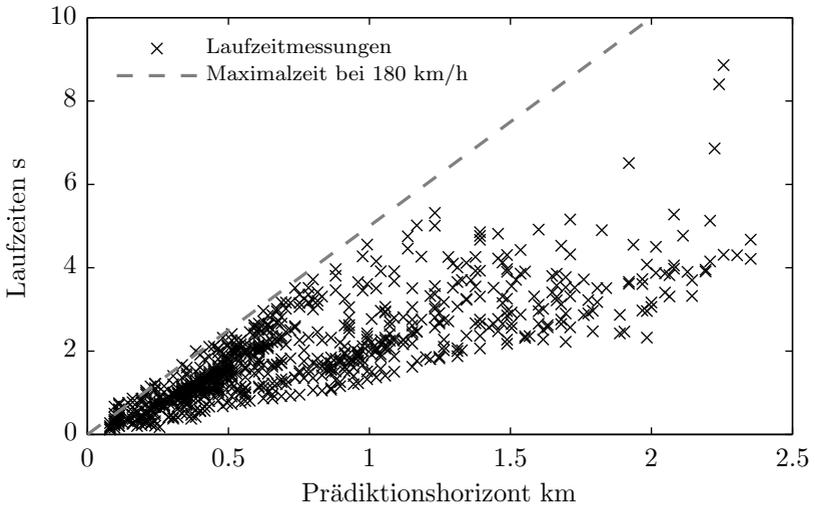


Abb. 6.15.: Laufzeitverhalten der MIDRANGE-Strategie in der Simulation [175]

Um jedoch zu gewährleisten, dass immer eine neue Strategie zur Verfügung steht, kann durch folgende Überlegungen eine Einschränkung an die maximale Berechnungszeit über den Prädiktionshorizont P_{horizon} getroffen werden [175]:

- Im schlechtesten Fall (worst case) stehen Daten erst bei der Hälfte des Prädiktionshorizonts zur Verfügung.
- Die Reichweite des Nahhorizonts ist aus Effizienzgründen mindestens doppelt so weit definiert, wie die des Regelhorizonts.

Für eine maximale Geschwindigkeit v_{max} kann somit über den Prädiktionshorizont eine obere maximale Laufzeit bestimmt werden:

$$t_{\text{max}} = \frac{1}{4} \cdot \frac{P_{\text{horizon}}}{v_{\text{max}}} \quad (6.5)$$

In Abb. 6.15 sind die Laufzeiten für eine simulierte Fahrt dargestellt. Bei kurzem Prädiktionshorizont verletzen einige Messungen die Bedingung der Maximalzeit. Da diese Phasen mit kurzem Prädiktionshorizont meist innerstädtisch auftreten, ist von einer niedrigeren maximalen Geschwindigkeit auszugehen, bei der wiederum die Einschränkung nicht verletzt wird.

7. Implementierung und Test

Die in Kapitel 6 vorgestellten Optimierungsstufen sollen in Simulation und Fahrversuch auf unterschiedlichen Strecken untersucht werden. Dabei werden insbesondere die MIDRANGE und LONGRANGE Optimierung sowie deren Zusammenspiel in der prädiktiven Regelung betrachtet. Während in der MIDRANGE Optimierung die Boxen-Variante in einem mehrdimensionalen Zustandsraum verwendet wird, werden in der LONGRANGE Optimierung die Geschwindigkeitsstrategie und Energiemanagementstrategie getrennt in jeweils eindimensionalen Zustandsräumen berechnet.

7.1. Simulation der mehrdimensionalen Optimierung

Für die Untersuchungen der MIDRANGE Optimierung wird die Stuttgart-Runde 3.4.2 als Fahrzyklus verwendet. Bei der Auslegung der heuristischen Betriebsstrategie wurde die Stuttgart-Runde als maßgeblicher Realzyklus verwendet, sodass ein simulatorischer Vergleich zwischen der heuristischen und der prädiktiven Betriebsstrategie auf dieser Strecke aussagekräftig ist. Dabei wird das vorausschauende Fahrprofil nach [54] gewählt.

Zunächst werden die Parameter der Optimierung durch charakteristische Use-Cases festgelegt, wodurch die Anforderungen an die multikriterielle Zielfunktion und deren Auswirkungen verdeutlicht werden. Es folgt ein Vergleich der heuristischen Basisstrategie mit der prädiktiven Optimalstrategie sowie eine Sensitivitätsanalyse unterschiedlicher Einflussfaktoren auf die Fahr- und Energiemanagementstrategie.

Des Weiteren folgt ein Vergleich einer getrennten, aufeinanderfolgenden (seriellen) Berechnung der Strategien mit dem mehrdimensionalen parallelen Ansatz der MIDRANGE Optimierung anhand einzelner Szenarien.

7.1.1. Parameterauslegung und Sensitivität

Die Gewichtung und Zusammensetzung einer Kostenfunktion ist entscheidend für das Ergebnis einer Optimierung. Für die MIDRANGE Optimierung wird eine Kostenfunktion wie in Abschnitt 4.1.1 beschrieben verwendet, die aus drei Kriterien besteht: Zeit $J^{|T|}$, Energie $J^{|E2|}$ und Komfort. Das Komfortkriterium setzt sich aus einer Bewertung des Ruckverhaltens $J^{|K1|}$ und der Bestrafung von dynamischen Vorgängen wie

Gangschaltungen und Verbrennungsmotorstarts $J^{[K2]}$ zusammen. Die Kostenfunktion lässt sich wie folgt beschreiben [176].

$$J_{\text{ges}} = \sum_{k=0}^N \frac{c_{\text{Time}} \cdot J_k^{[T]} + c_{\text{Energy}} \cdot J_k^{[E2]} + c_{\text{Jerk}} \cdot J_k^{[K1]} + c_{\text{Dyn}} \cdot J_k^{[K2]}}{c_{\text{Time}} + c_{\text{Energy}} + c_{\text{Jerk}} + c_{\text{Dyn}}} \quad (7.1)$$

Da die einzelnen Kosten im Wertebereich $[0,1]$ liegen, ist die Gesamtkostenfunktion mit den einzelnen Gewichtungsfaktoren c_i ebenso definiert in $J_{\text{ges}} \in [0,1]$.

Exemplarische Fahr Situationen (Use-Cases)

Für die Festlegung geeigneter Gewichtungsparameter werden acht exemplarische Fahr Situationen betrachtet, die unterschiedliche Beschleunigungs-, Verzögerungs- und Konstantfahranteile aufweisen sowie die Topografie und unterschiedliche Batterieladezustände abbilden. In Tab. 7.1 sind die einzelnen Use-Cases charakterisiert.

Tab. 7.1.: Exemplarische Fahr Situationen (Use-Cases) nach [176]

Use-Case	Höchstgeschwindigkeit (km/h)	Steigung (%)	SoC _{start} (%)
1	100 - 100	0	60 /15
2	0 - 100	0	60 /15
3	100 - 30	0	60 /15
4	50 - 50	-10	60 /15
5	100 - 70 - 100	0	60 /15
6	70 - 100 - 70	0	60 /15
7	70 - 70	(-5) - 0 - (+5)	60 /15
8	50 - 10 - 50 - 10 - 50 - 10	0	60 /15

In Abb. 7.1 sind die Ergebnisse unterschiedlicher Gewichtungsfaktoren $P_i(c_{\text{Energy}}, c_{\text{Time}}, c_{\text{Jerk}}, c_{\text{Dyn}})$ für die Use-Cases als normierter Verbrauch über der normierten Durchschnittsgeschwindigkeit eingezeichnet. Die nicht-dominierten Ergebnisse bilden eine Pareto-Front (grau) [150]. Die zeitoptimale $P_{22}(0,4,1,4)$ und energieoptimale $P_1(4,0,3,1)$ Kombination der Gewichtungen sind hervorgehoben (Kreis). Dabei ist zu erkennen, dass beim zeitoptimalen Ergebnis dynamische Vorgänge stark bestraft werden, während ein energieoptimales Ergebnis mit besonders wenig Ruck erreicht wird.

Die Pareto-optimalen Kombinationen sind in Abb. 7.2 als prozentuale Anteile der einzelnen Gewichtungsfaktoren an der Summe der Faktoren aufgezeichnet. Zeit und Energie sind als gegensätzliche Zielvorgaben klar zu erkennen. Die Bestrafung durch die Komfortgrößen ist sowohl für energetisch optimales als auch zeitoptimales Verhalten notwendig, um vorgegebene Grenzen des Fahrkomforts zu erreichen. Darüber hinaus wird ein niedriger Verbrauch durch ein ruckfreies und ruhiges Fahrverhalten begünstigt. Eine zeitoptimale Abstimmung hängt stark von der oberen Grenze eines vorgegebenen Geschwindigkeitsschlauchs ab. Wenig dynamische Schaltungen begünstigen ein schnelles Erreichen und Fahren an dieser Grenze.

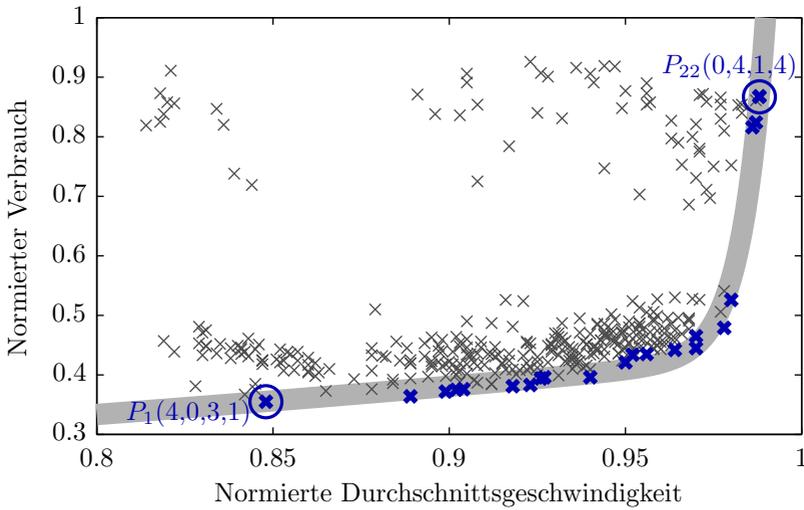


Abb. 7.1.: Pareto-Front aus unterschiedlichen Gewichtungsfaktoren für exemplarische Fahrsituationen (Use-Cases siehe Tab. 7.1)

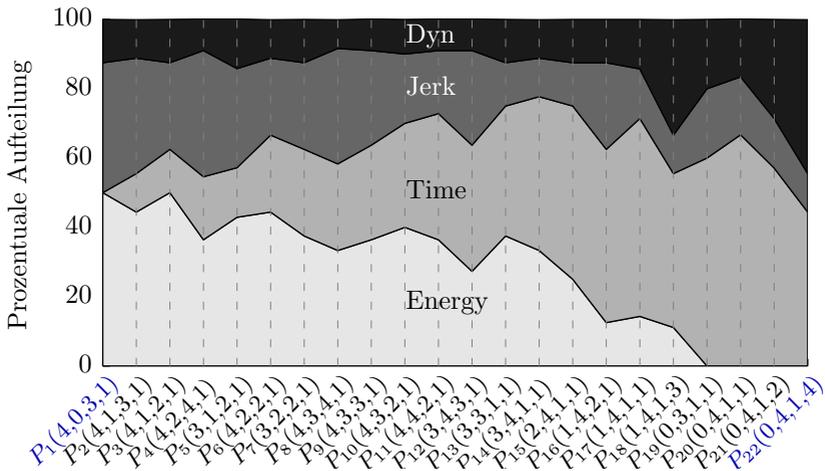


Abb. 7.2.: Parameter der Pareto-Front aus Abb. 7.1 nach [176]

Die erarbeiteten Parameterkombinationen und deren Extrema werden in der weiteren Untersuchung der Optimierung verwendet.

7.1.2. Vergleich der optimalen mit der heuristischen Strategie

Die prädiktive Optimalstrategie wird mit der heuristischen Basisstrategie verglichen. Dabei erfolgt die Simulation der optimalen Strategie in MATLAB/C, während die Basisstrategie durch die Fahrleistungs- und Verbrauchssimulationssoftware AVL CRUISE [74] berechnet wird.

Das Fahrzeugmodell bei der prädiktiven Strategie ist quasi-stationär abgebildet, während einzelne Komponenten, wie z. B. die Batterie, bei der Basisstrategie dynamisch modelliert sind. Um eine Vergleichbarkeit zwischen der dynamischen und quasi-stationären Modellierung der beiden Simulationen zu gewährleisten, werden berechnete Steuertrajektorien (Drehzahl, Momente, etc.) der prädiktiven Strategie über eine Schnittstelle an CRUISE übergeben. Das resultierende Systemverhalten beider Simulationen wird durch eine Residuenanalyse bewertet sowie Korrekturmaßnahmen daraus abgeleitet [176].

Da der SoC bei einer Stuttgart-Runde aufgrund der dynamischen Modellierung um 4 % sowie der Kraftstoffverbrauch um 2 % abweicht, werden bei der prädiktiven Strategie auf den absoluten Verbrauch $m_{f,stat}$ Korrekturwerte dazu gerechnet.

Der erste Korrekturwert umfasst die Differenz des Verbrauchs zwischen quasi-stationärer Berechnung $m_{f,stat}$ und dynamischer Berechnung $m_{f,dyn}$:

$$\Delta m_{f,k1} = m_{f,dyn} - m_{f,stat} \quad (7.2)$$

Der in Abschnitt 2.2.3 beschriebene Energiekostenindex (EKI) stellt einen Äquivalenzfaktor dar, mit dem eine Differenz des SoCs am Ende eines Zyklus in Kraftstoffverbrauch umgerechnet werden kann.

Die CRUISE Simulation rechnet in Zeitschritten, während die prädiktive Strategie positionsabhängig berechnet wird. Bei der zeitlichen Betrachtung sinkt der SoC durch Standphasen an Kreuzungen und Ampeln, bei denen zwar der Verbrennungsmotor nicht läuft, der Bordnetzbedarf aber gedeckt werden muss. Diese Leistungen fehlen und müssen bei der positionsabhängigen Berechnung korrigiert werden, indem aus der zeitlichen Differenz⁷⁶ Δt_{zykl} der beiden Berechnungen und der Bordnetzleistung P_{BN} eine zusätzliche Energie $\Delta E_{BN} = P_{BN} \cdot \Delta t_{zykl}$ berechnet wird.

Die Differenzenergie aus dem SoC am Ende des Zyklus $\Delta E_{SoC,end}$ und die zusätzliche Energie aus den Standphasen ΔE_{BN} wird über den EKI in einen Kraftstoffkorrekturterm $\Delta m_{f,k2}$ umgerechnet:

$$\Delta m_{f,k2} = (\Delta E_{SoC,end} + \Delta E_{BN}) \cdot \text{EKI} \quad (7.3)$$

⁷⁶ Kleine Abweichungen in der Durchschnittsgeschwindigkeit werden durch die Korrektur über die zeitliche Differenz mitberücksichtigt.

Der korrigierte Verbrauch der prädiktiven Strategie ist somit:

$$m_{f,\text{korr}} = m_{f,\text{stat}} + \Delta m_{f,k1} + \Delta m_{f,k2} \quad (7.4)$$

Analyse der Energiemanagementstrategien

Der Prädiktionshorizont der MIDRANGE Optimierung wird auf die gesamte Streckenlänge der Stuttgart-Runde ausgedehnt, sodass die prädiktive Strategie in einem Rechenschritt berechnet werden kann. Die Geschwindigkeit der prädiktiven Strategie weicht im Durchschnitt um 0,8 m/s vom vorgegebenen v-Profil der Stuttgart-Runde ab. Start- und Endgeschwindigkeiten sowie Batterieladezustände werden identisch gewählt. Die Bordnetzleistung ist mit 1 kW konstant festgelegt.

Die heuristische Basisstrategie ist, wie in Kap. 3.2.1 beschrieben, durch zwei Phasen gekennzeichnet. In der Charge Depleting (CD) Phase wird, wenn möglich, elektrisch gefahren und der Verbrennungsmotor nur gestartet, wenn die geforderte Leistung die der E-Maschine übersteigt. Nach etwa 27 km und einem SoC von 19% wird in den Charge Sustaining (CS) Modus gewechselt, der in Abb. 7.3 durch eine senkrechte gestrichelte Linie gekennzeichnet ist. Die Ladestrategie erfolgt nun in einem SoC-Band im unteren Energiebereich der Batterie (siehe Abschnitt 3.2.1). Die prädiktive Strategie entlädt die Batterie kontinuierlich im Sinne einer Blending-Strategie (siehe Abschnitt 3.2.1).

Energetische Analyse: Wird die prozentuale Aufteilung der Gesamtenergie E_{ges} über der Strecke in rein elektrischer Fahrt (E-Drive), bei Lastpunktverschiebung (LPV) und Rekuperation (Reku) verglichen, werden die Unterschiede der beiden Strategien deutlich:

Während bei der Basisstrategie 75 % der rein elektrischen Fahrt in der CD-Phase und die komplette Lastpunktverschiebung in der CS-Phase stattfindet, wählt die prädiktive Strategie eine Gleichverteilung beider Modi über die gesamte Strecke aus. Die gesamte rekuperierte Energie ist durch die enge Vorgabe des Geschwindigkeitsprofils nahezu identisch.

Die elektrischen Leistungen in der Lastpunktverschiebung sind bei der Basisstrategie stark eingeschränkt auf maximal 15 kW, wodurch eine hohe E-Maschinenbelastung sowie Derating⁷⁷ der E-Maschine durch längere Leistungsanforderungen verhindert wird. Die prädiktive Strategie fordert maximale Leistung von der E-Maschine. Eine Leistungsreduzierung aufgrund thermischer Belastung ist in der prädiktiven Strategie nicht vorgesehen, kann aber in der Kostenfunktion hinzugefügt werden.

Die Zeitanteile der einzelnen Hybridmodi sind in Abb. 7.4 dargestellt. Dabei ist die elektrische Fahrt mit 48 % und 49 % der am häufigsten gewählte Modus. Während die Basisstrategie diesen Modus zum größten Teil in der CD-Phase einsetzt, werden bei der prädiktiven Strategie die gleichen E-Fahrt Anteile auf den ganzen Zyklus verteilt.

⁷⁷ Einschränkung der elektrischen Leistung durch Überhitzung der E-Maschine

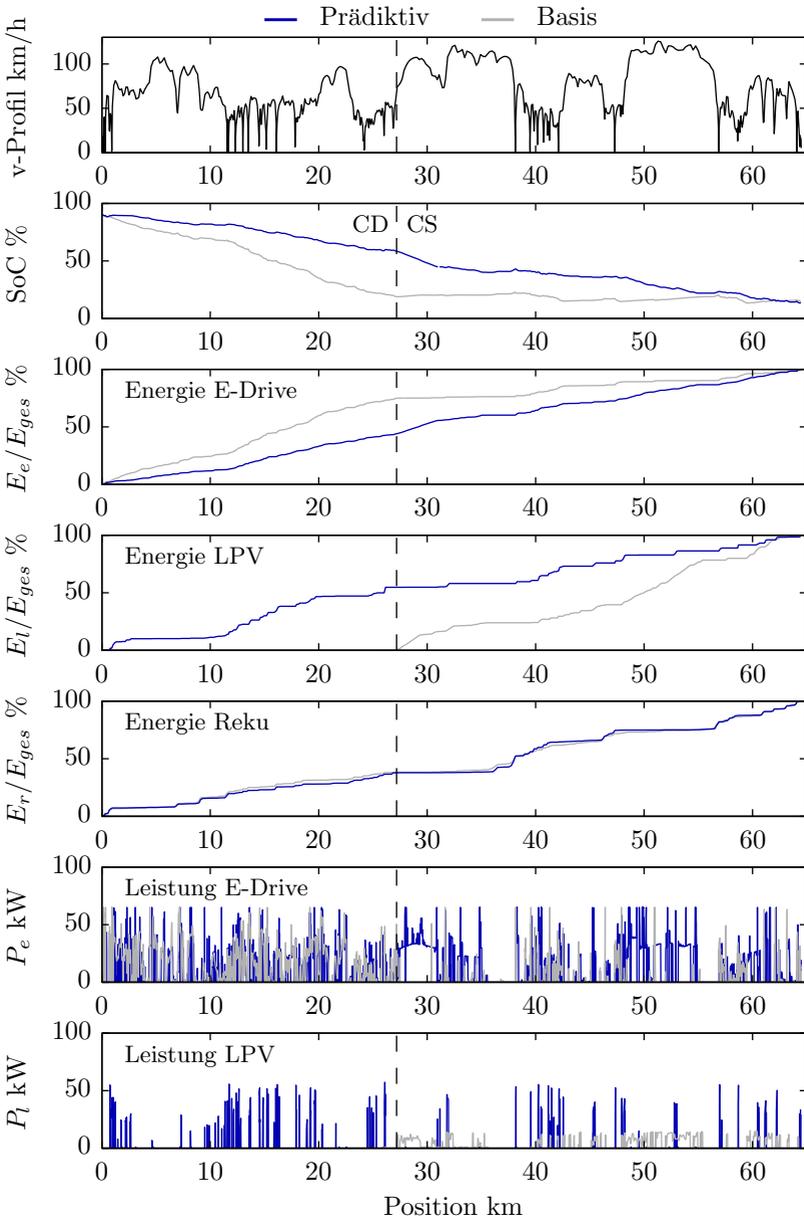


Abb. 7.3.: Vergleich der prädiktiven Optimalstrategie mit der heuristischen Basisstrategie nach [176]

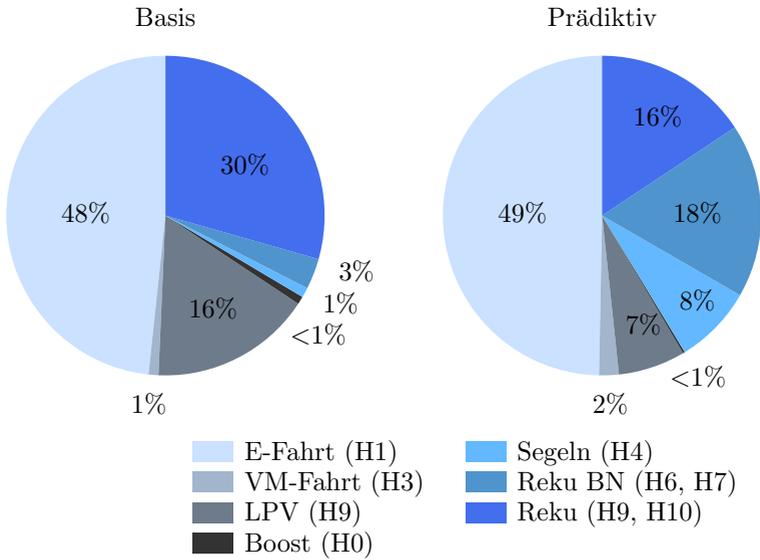


Abb. 7.4.: Zeitanteile der Hybridmodi beider Strategien nach [176]. Die Hybridmodi H_i sind nach Abschnitt 2.2.3 definiert und teilweise zusammengefasst.

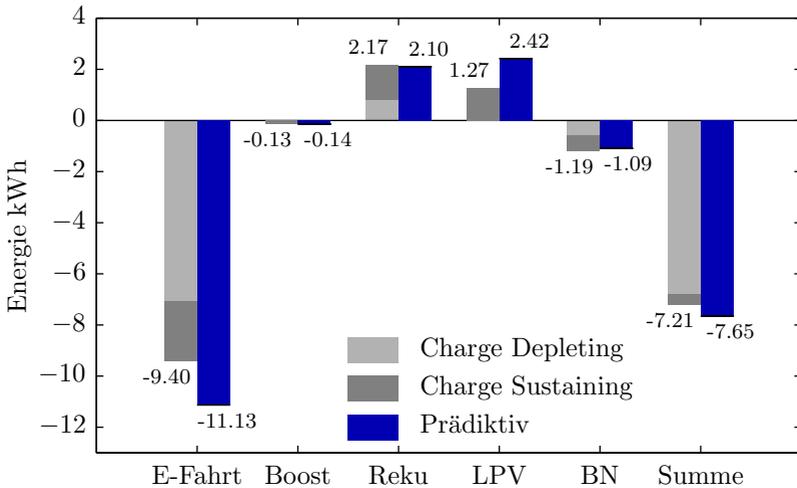


Abb. 7.5.: Aufteilung der Energien beider Strategien nach [176]

Während die Basisstrategie gerade in der CS-Phase besonders die Lastpunktverschiebung verwendet, ist der Anteil der Segelphase in der prädiktiven Strategie mit 8 % deutlich höher als bei der Basisstrategie. Neben Segeln sind die Bordnetz Rekupe-
rationsphasen der prädiktiven Strategie mit 18 % sogar höher als die Rekuperation zum Laden der Batterie. Generell bestätigen der größere Anteil an Segeln und Rekupe-
rationsphasen der prädiktiven Strategie die vorausschauend abgestimmte Wahl der Hybridmodi.

Bei gleichem zeitlichem Anteil der E-Fahrt (ca. 49 % in Abb. 7.4) zeigt sich in Abb. 7.5 eine deutlich höher eingesetzte Energie in der prädiktiven Strategie. Dies ist zu begründen, da sich die durch die E-Maschine zurückgelegte Strecke von 26,6 km der Basisstrategie um 18,8 % auf 32,7 km bei der prädiktiven Strategie erhöht. Da-
durch verbessert sich neben der erhöhten Antriebsleistung auch der gesamtelektrische Wirkungsgrad von 80,1 % auf 84,5 % [176].

Der zeitliche und energetische Anteil der Rekuperation ist in beiden Strategien nahezu gleichgroß, sodass die für die E-Fahrt notwendige zusätzliche Energie in der prädiktiven Strategie über die Lastpunktverschiebung erzeugt werden muss.

Da die zeitlichen Anteile der LPV in der prädiktiven Strategie um mehr als die Hälfte kleiner sind als bei der Basisstrategie, folgt eine aggressive Nachladestrategie mit 190 % höherer Energieaufwendung (siehe Abb. 7.5).

Die Summe aller Energien, die aus der HV-Batterie entnommen werden, unter-
scheidet sich bei den jeweiligen Strategien durch das Entladeverhalten. Durch die Berücksichtigung der spannungsabhängigen Wirkungsgrade der Batterie können so bei der prädiktiven Strategie 6,1 % mehr Energie entnommen werden, wobei der SoC am Ende des Zyklus um 0,9 % abweicht.

Eine effiziente Ausnutzung der Lastpunktverschiebung wird beim Vergleich der gewählten Betriebspunkte des Verbrennungsmotors und der E-Maschine in Abb. 7.6 deutlich. Während die durchschnittliche Ladeleistung der Basisstrategie durch die E-Maschine bei 7,1 kW liegt, lädt die prädiktive Strategie 32,3 kW in die Batterie. Sowohl im Verbrennungsmotorkennfeld als auch im E-Maschinen Kennfeld liegen die Betriebspunkte deutlich in Bereichen optimaler Wirkungsgrade. Es werden deutlich höhere Drehzahlen angefahren, wobei Schaltvorgänge stark reduziert werden. Die prädiktive Ausnutzung der Wirkungsgrade bewirkt eine Verbesserung des EKI von 0,47 l/kWh der Basisstrategie auf 0,34 l/kWh der prädiktiven Strategie. Das bedeutet, dass eine durch die Lastpunktverschiebung generierte Energie von einer kWh durch die Prädiktion nur noch mit 72 % des von der Heuristik benötigten Kraftstoffs aufgebracht werden muss [176].

Auch wenn die zeitlichen Anteile der Rekuperationsphasen (nur Batterieladung durch Rekuperation: Reku in Abb. 7.4) bei der Basisstrategie bei 30 % liegen und bei der prädiktiven nur bei 16 %, zeigen die Betriebspunkte im E-Maschinen Kennfeld der prädiktiven Strategie eine bessere Ausnutzung des Wirkungsgrads auf (siehe Abb. 7.7).

Der gesamtelektrische Wirkungsgrad wird von 79,0 % auf 85,1 % gesteigert, wodurch in Rekuperationsphasen bei der Basisstrategie nur 6,9 kW und in der prädiktiven 12,1 kW in die Batterie geladen werden können.

Energetisch besonders vorteilhaft ist die Bordnetzrekuperation und das Segeln in der prädiktiven Strategie, bei der die aufgenommene Energie direkt zur Deckung der Bordnetzleistung verwendet wird oder leichtes Entladen der Batterie im Segeln hingenommen wird. Doppelte Energieverluste durch den Wirkungsgrad der E-Maschine und der Batterie beim Laden und Entladen in Rekuperationsphasen werden bei einer prädiktiven Strategie weitestgehend vermieden.

Einsparpotenzial: Bei der Basisstrategie ist in der CS-Phase ein vollständiges, geplantes Entladen der Batterie auf $\text{SoC}_{\text{end}} = 10 \%$ nicht möglich, da nur durch das Wissen über die genaue Zielposition ein Entladen auf diesen Wert sinnvoll ist. Der Ladezustand von $\text{SoC}_{\text{end}} = 14,3 \%$ wird zum direkten Vergleich für die prädiktive Strategie (Prädiktiv 1a) mit einer Abweichung von $< 1 \%$ vorgegeben. Durch die genaue Kenntnis über der Strecke kann in einer zweiten prädiktiven Strategie (Prädiktiv 1b) die gesamte Energie aus der Batterie verwendet werden. Die Zielvorgabe des Ladezustands am Ende des Zyklus wird somit auf $\text{SoC}_{\text{end}} = 10 \%$ gesenkt.

In Tab. 7.2 sind die Einsparpotenziale der beiden Varianten zur Basisstrategie aufgeschlüsselt. Die Absolutverbrauchswerte der prädiktiven Strategien werden mit den in Gl. 7.4 vorgestellten Korrekturtermen berechnet.

Auch wenn durch die Vorgabe der Fahrstrategie die Geschwindigkeit und damit auch der Komfort unwesentlich beeinflusst wird, werden die Schaltvorgänge der Basisstrategie mit 6,2 Schaltungen pro Kilometer auf 2,6 Schaltungen pro Kilometer in der prädiktiven Strategie reduziert. Im Vergleich dazu erfolgten 1,2 Motorstartanforderungen pro Kilometer bei der Basisstrategie und 1,1 Starts pro Kilometer bei der prädiktiven Strategie.

Reduktion des $\text{SoC}_{\text{start}}$: Eine vollständig geladene Batterie zu Beginn der Fahrt ist in Realität nicht immer möglich. Im Folgenden soll untersucht werden, wie eine niedriger $\text{SoC}_{\text{start}}$ sich auf die beiden Strategien und ihren Energieverbrauch bzw. deren Einsparpotential verhält.

In Abb. 7.8 sind die SoC-Verläufe der beiden Strategien für $\text{SoC}_{\text{start}} = \{90, 70, 50, 30, 15\} \%$ über der Strecke aufgezeigt. Dabei sind die Wechsel der Basisstrategie von der CD-Phase zur CS-Phase markiert (Kreis). Dieser Wechsel markiert die AER (siehe Abschnitt 3.2.1) und geschieht jeweils beim Unterschreiten von $\text{SoC} = 21,4 \%$. Je niedriger die Batterieladung am Anfang des Zyklus, desto früher wird die Grenze zur Umschaltung erreicht. Bei $\text{SoC}_{\text{start}} = 15 \%$ verhalten sich die Strategien des PHEVs wie bei einem HEV mit kleiner Batterie und ohne zusätzliche Energie durch externe Nachlademöglichkeiten.

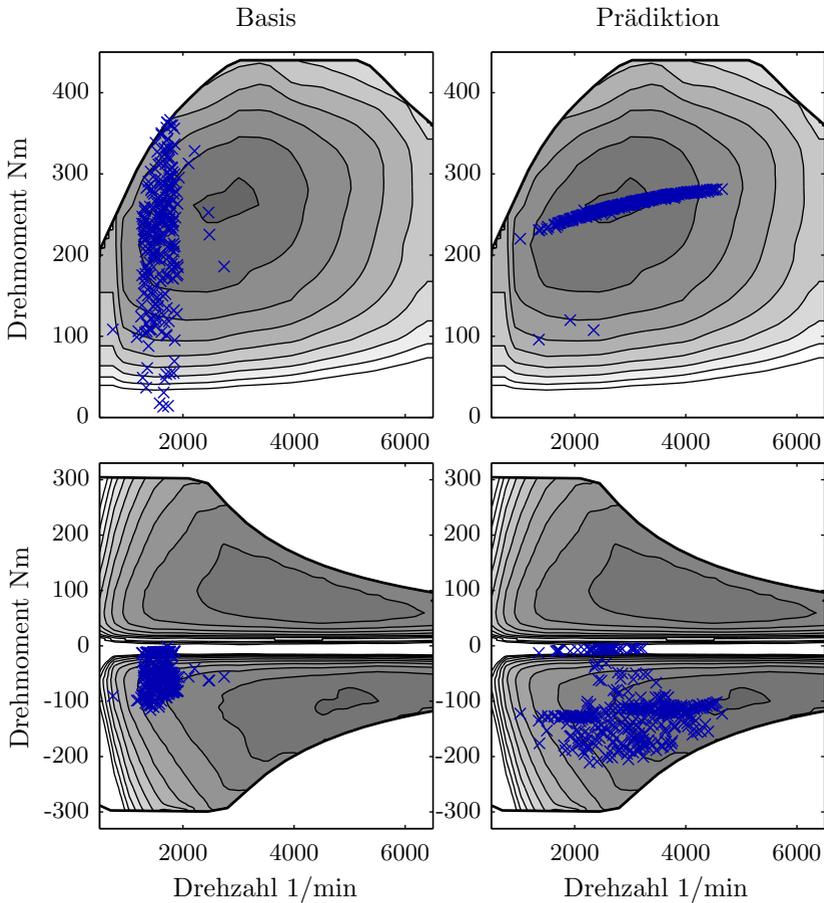


Abb. 7.6.: Vergleich der Betriebspunkte bei der Lastpunktverschiebung beider Strategien nach [176]

Tab. 7.2.: Einsparpotenzial durch die prädiktive Strategie bei unterschiedlichem SoC_{end} nach [176]

Strategie	SoC _{end} (%)	\bar{v} (km/h)	$m_{f,\text{kor}}$ (l/100km)	Potenzial (%)
Basis	14,3	59,8	4,02	-
Prädiktiv 1a	13,4	59,1	3,71	7,8
Prädiktiv 1b	10	59,4	3,58	10,9

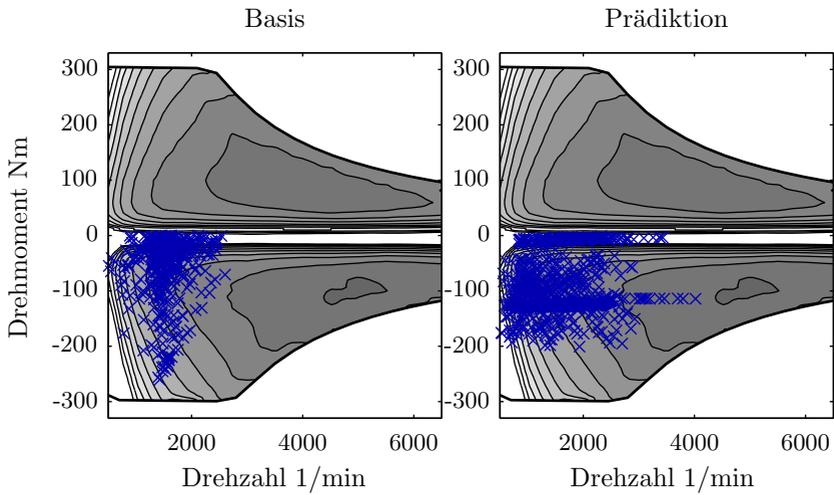


Abb. 7.7.: Vergleich der Betriebspunkte während der Rekuperation beider Strategien nach [176]

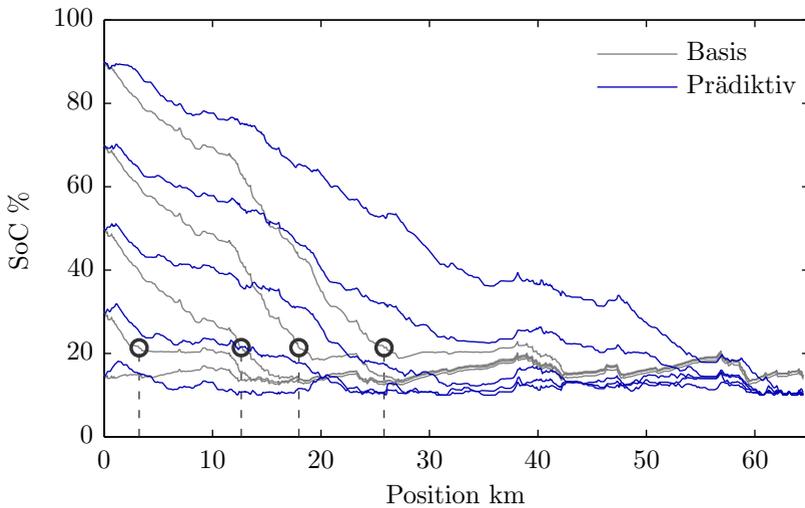


Abb. 7.8.: Variation des $\text{SoC}_{\text{start}}$ bei der Basisstrategie und der prädiktiven Strategie

Das heuristische Verhalten der Basisstrategie ist durch den nahezu identischen Verlauf der Strategien auf den letzten Kilometern charakterisiert, während die prädiktive Strategie die elektrische Energie über der gesamten Strecke neu verteilt.

Die Aufteilung der elektrischen Energie je SoC_{start} in der prädiktiven Strategie ist zusammen mit der prozentualen Verbrennerlaufzeit t_{ICE} in Abb. 7.9 (oben) dargestellt. Während die rekuperierte Energie unverändert bleibt, wird die elektrische Leistung für die E-Fahrt aus der LPV gewonnen, da die gesamte Energie aus der Batterie begrenzt ist. Der prozentuale Zeitanteil des laufenden Verbrennungsmotors steigt von ca. 9,0 % auf 17,2 % bei abnehmendem SoC_{start} .

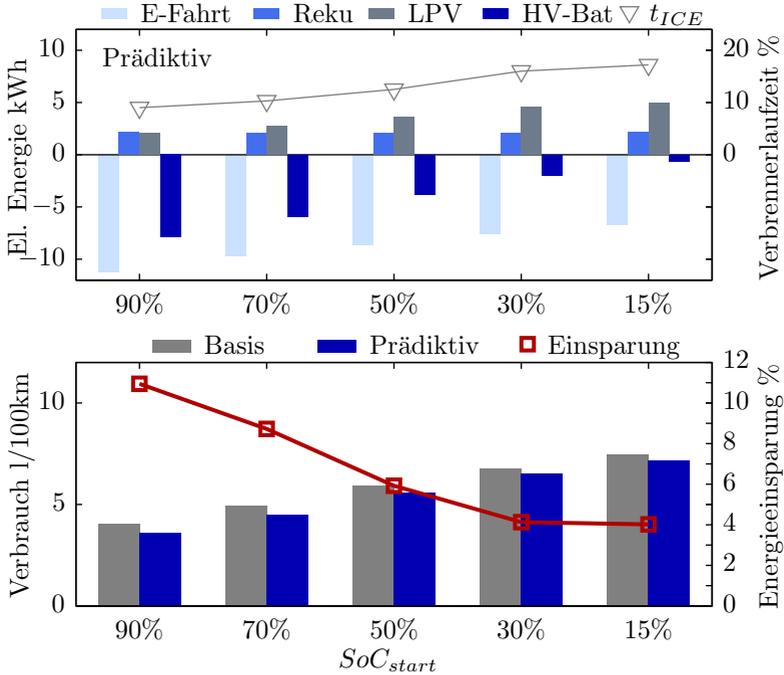


Abb. 7.9.: Einfluss der Reduktion des SoC_{start} auf die Aufteilung der elektrischen Energien und den Kraftstoffverbrauch [176]

Der Vorteil einer prädiktiven Strategie ist bezüglich der Energieeinsparung bei voller Batterie zu Beginn des Zyklus maximal und nimmt bei sinkendem SoC_{start} ab, wie in Abb. 7.9 (unten) dargestellt.

Dabei nähert sich das Energieeinsparpotenzial asymptotisch einem Wert von 4 %, der auch noch bei einer kleinen Batterie vergleichbar zu einem HEV erreicht wird, da die Rekuperationenergie prädiktiv und vollständig aufgenommen werden kann. Dies bekräftigt die Notwendigkeit einer vorausschauenden Strategie bei optimaler Regelung eines PHEVs, gerade da deren Batteriekapazität in Zukunft steigen wird.

Variation der Streckenlänge: In einer weiteren Untersuchung wird die geplante Streckenlänge reduziert. Die heuristische Basisstrategie verhält sich auch bei einem verkürzten Zyklus identisch, während die prädiktive Strategie das Energiemanagement auf die vorgegebene Streckenlänge anpasst. In Abb. 7.10 sind die SoC-Verläufe der Basisstrategie (grau) sowie der prädiktiven Strategie für unterschiedlich lange Strecken der Stuttgart-Runde zu sehen. Dabei wird die Streckenlänge um jeweils fünf Kilometer verlängert.

Es ist deutlich zu erkennen, dass die prädiktive Strategie bei Streckenlängen bis etwa 30 km⁷⁸ die Batterie vergleichbar zur heuristischen Strategie in der CD-Phase durch rein elektrisches Fahren entlädt. Während die heuristische Strategie ab einer Vorgabe von 25 km in die CS-Phase wechselt, nutzt die prädiktive Strategie den vollen Batterieladeinhalt bis zu $\text{SoC}_{\text{end}} = 10\%$ aus.

Vergleicht man den absoluten Kraftstoffverbrauch der Strategien je Streckenlänge, so lässt sich die Stuttgart-Runde bezüglich der prädiktiven Information in drei Phasen einteilen (siehe Abb. 7.11) [176]:

- **Phase 1:** Sowohl die heuristische als auch die prädiktive Strategie wählen bei Strecken bis zur AER den Hybridmodus E-Fahren. Da die heuristische Strategie auf Lastanforderungen nur reagieren kann, kommt es vereinzelt zu kurzen Verbrennungsmotorstarts. Dadurch entsteht ein kleiner Kraftstoffverbrauch ($\Delta m_f < 0,1 l$). Die prädiktive Strategie verhindert diese unnötigen Motorwiederstarts durch die Vorausschau und kann somit die Verbrennerlaufzeiten stark senken, sodass in dieser Phase eine Verbrauchseinsparung von 50-100 % möglich ist.
- **Phase 2:** Nach dem Wechsel der Basisstrategie in die CS-Phase kann die prädiktive Strategie die elektrische Reichweite vergrößern, während die Basisstrategie schon den Verbrennungsmotor zuschalten muss. Der Differenzverbrauch der beiden Strategien liegt über $\Delta m_f > 0,4 l$, wodurch in dieser Phase Verbrauchseinsparungen zwischen 50 -75 % möglich sind.
- **Phase 3:** Der Vorteil der vergrößerten elektrischen Reichweite nimmt mit zunehmender Streckenlänge ab. Durch eine vorausschauende Lastpunktverschiebung entsteht ein Einsparpotenzial zwischen 10-25 %, das bei weiterer Streckenverlängerung weiter abnimmt.

Bei unendlich langer Strecke reduziert sich der prozentuale Vorteil der elektrischen Reichweite eines PHEVs zu einem HEV Fahrzeug und somit auch die Verbrauchseinsparung, solange der Zyklus keine längeren Ladevorgänge durch längere Autofahrten aufweist. Eine absolute Verbrauchseinsparung bleibt bei der prädiktiven Strategie dennoch bestehen.

⁷⁸ Entspricht etwa der gesamtelektrische Reichweite (AER)

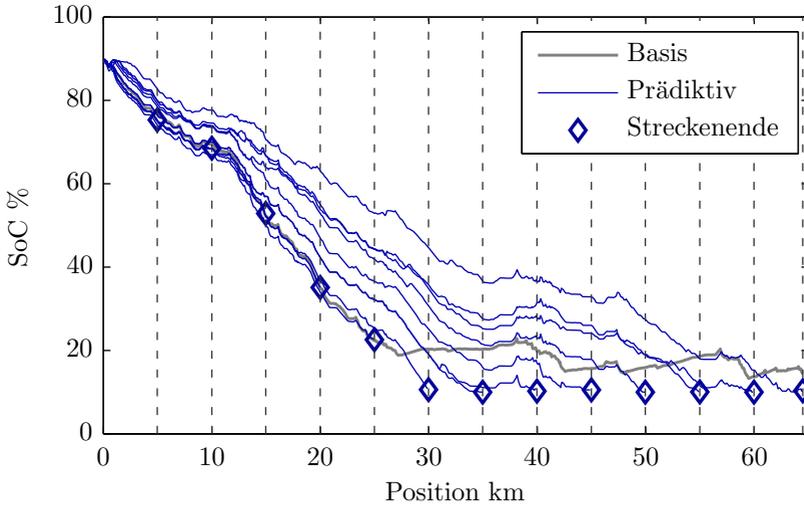


Abb. 7.10.: Variation der Streckenlänge der prädiktiven Strategie

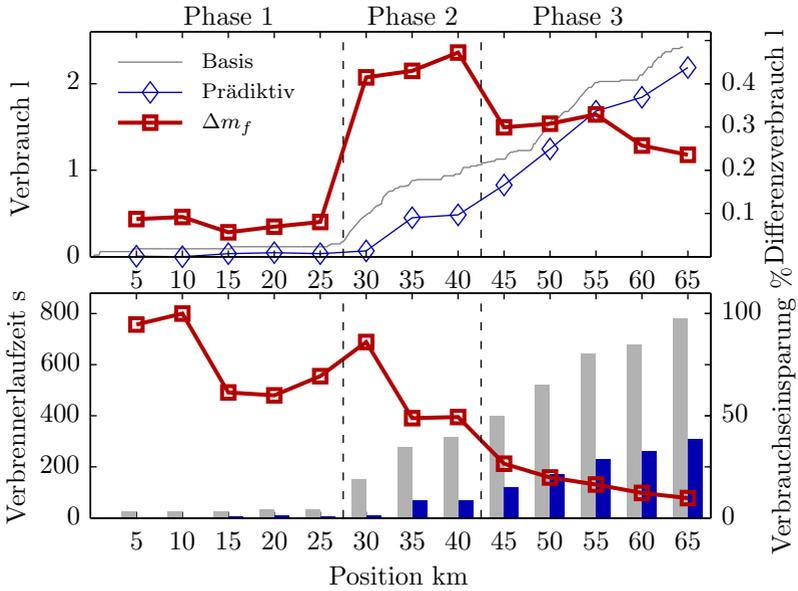


Abb. 7.11.: Verbrauchseinsparung in drei unterschiedlichen Phasen bei einer Variation der Streckenlänge im Vergleich beider Strategien

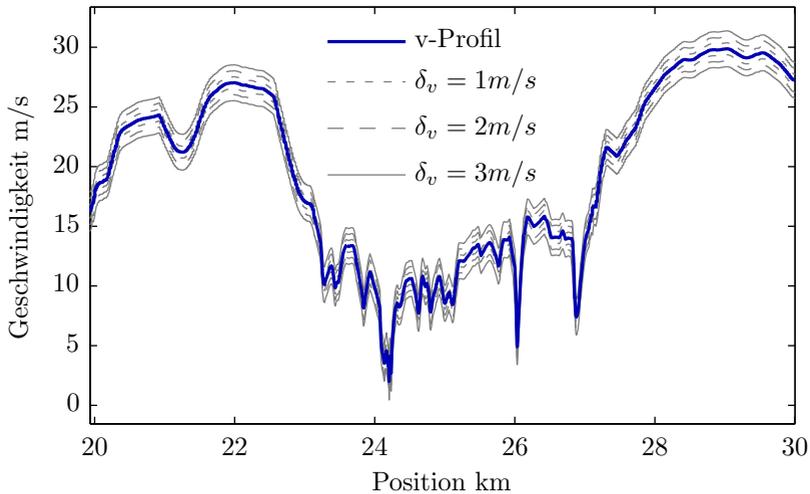


Abb. 7.12.: Fahrschläuche unterschiedlicher Breiten δ_v um das Geschwindigkeitsprofil der Stuttgart-Runde

Festlegung eines Fahrschlauchs: Die heuristische Basisstrategie beeinflusst die Geschwindigkeit nicht, da sie durch ihre Regeln nur auf diese reagieren kann. Während für einen direkten Vergleich der Energiemanagementstrategien die Optimierung der Fahrstrategie nahezu vernachlässigt wird, folgen Untersuchungen bei denen die Fahrstrategie in der prädiktiven Strategie mitberücksichtigt wird. Dies erfolgt über einen Fahrschlauch, der eng um das Geschwindigkeitsprofil der Stuttgart-Runde gelegt wird. Bei der Analyse der Fahrstrategien wird der Fahrschlauch um das Geschwindigkeitsprofil vergrößert. Neben der optimalen Energiemanagementstrategie kann so auch die Geschwindigkeit in diesem Fahrschlauch angepasst werden, um somit die Potenziale der prädiktiven Strategie zu erhöhen.

In Abb. 7.12 sind drei Fahrschläuche mit unterschiedlichen Breiten δ_v und das vorgegebene Geschwindigkeitsprofil eines Ausschnitts der Stuttgart-Runde zu sehen.

Analyse der Fahrstrategie

Zur Untersuchung der Wechselwirkungen der Energiemanagementstrategien mit optimalen Fahrstrategien wird die Breite des Fahrschlauchs δ_v vergrößert. Dadurch wird das Fahrprofil der Stuttgart-Runde nicht vorgegeben, sondern durch die Optimierung im Rahmen der Grenzen beeinflusst.

In Abb. 7.13 ist der spezifische Kraftstoffverbrauch über der Durchschnittsgeschwindigkeit \bar{v} für drei unterschiedlich parametrisierte Kostenfunktionen (Prädiktiv 1,2 und 7) der Basisstrategie gegenübergestellt.

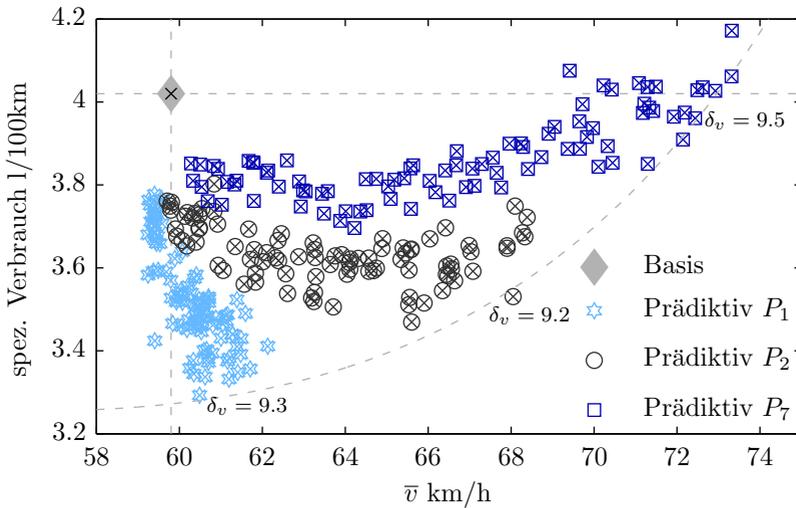


Abb. 7.13: Variation der Fahrschlauchbreite bei unterschiedlichen Ausprägungen der Kostenfunktion im Vergleich zur Basisstrategie

Die Fahrschlauchbreite wird zwischen $\delta_v = 1$ m/s und $\delta_v = 10$ m/s variiert. Prädiktiv 1 gewichtet mit (4,0,3,1) den Energieverbrauch stärker, während die zeitliche Betrachtung mit Wert Null nicht berücksichtigt wird. Eine Vergrößerung des Fahrschlauchs führt bei dieser Parametrierung zu einem kleinen Anstieg der Durchschnittsgeschwindigkeit, während der spezifische Verbrauch deutlich gesenkt werden kann. Bei einer Fahrschlauchbreite von $\delta_v = 9,3$ wird ein spezifischer Kraftstoffverbrauch von 3,29 l/100km bei einer Durchschnittsgeschwindigkeit von 60,49 km/h erreicht. Bei einer um 1,15 % höheren Durchschnittsgeschwindigkeit wird im Vergleich zur Basisstrategie 18,1 % Kraftstoff eingespart.

Prädiktiv 2 (4,1,3,1) und Prädiktiv 7 (3,2,2,1) sind prädiktive Fahr- und Energiemanagementstrategien mit der Parametrierung nach Abschnitt 7.1.1, bei denen das zeitliche Verhalten in der Kostenfunktion bewertet wird und dadurch höhere Durchschnittsgeschwindigkeiten möglich sind.

In Tab. 7.3 sind zwei weitere Fälle entlang der Pareto-Front in Abb. 7.13 herausgegriffen. Bei einer um 13,8 % höheren Durchschnittsgeschwindigkeit zur Basisstrategie werden 12,17 % Kraftstoff eingespart, während bei nahezu gleichem Verbrauch mit 72,44 km/h die Durchschnittsgeschwindigkeit um 21,13 % zur Basisstrategie angehoben werden kann.

Tab. 7.3.: Einsparpotenzial durch Vergrößern der Fahrschlauchbreite δ_v für prädiktive Strategien mit unterschiedlich gewichteten Kostenfunktionen

Strategie	\bar{v} (km/h)	$\Delta\bar{v}$ (%)	m_f (l/100km)	Δm_f (%)	δ_v (m/s)
Basis	59,8	-	4,02	-	0
Prädiktiv 1	60,49	1,15	3,29	18,09	9,3
Prädiktiv 2	68,05	13,8	3,53	12,17	9,2
Prädiktiv 7	72,44	21,13	3,96	1,47	9,5

Einfluss der Fahrschlauchbreite auf Komfort: Durch die Vergrößerung der Fahrschlauchbreite können energetisch ungünstige Fahrscenarien des vorgegebenen Geschwindigkeitsprofils der Stuttgart-Runde angepasst werden. Der Komfort ist dabei kein gegensätzliches Ziel zur Einsparung des Kraftstoffs.

In Abb. 7.14 sind mehrere Kenngrößen über eine variierte Fahrschlauchbreite von $\delta_v \in [1, 10]$ m/s aufgetragen. Einzelne Messpunkte (grau) einer Parameterkombination werden durch eine angepasste Polynomfunktion repräsentiert.

Während der spezifische Verbrauch bei Prädiktiv 1 quadratisch abfällt, steigt bei einer Gewichtung der Zeit (Prädiktiv 2 und 7) der Kraftstoffverbrauch bei größeren Fahrschlauchbreiten ($\delta_v^{P_2} = 8$ m/s und $\delta_v^{P_7} = 3,8$ m/s) wieder an.

Die Durchschnittsgeschwindigkeit verhält sich linear zur Fahrschlauchbreite, wobei bei zunehmender zeitlicher Gewichtung der Gradient zunimmt sowie die Streuung der einzelnen Abweichungen abnimmt.

Die Anzahl der Gangschaltungen, der Motorstartvorgänge sowie der mittlere Ruck nimmt bei kleineren Fahrschlauchbreiten stark exponentiell ab. Dabei kann bei maximaler Fahrschlauchbreite von $\delta_v = 10$ m/s die Anzahl der Gangschaltungen um bis zu 37,5 % reduziert werden. Die Anzahl der Motorstartvorgänge reduziert sich unabhängig von den drei betrachteten Parameterkombinationen um bis zu 75 %.

Der mittlere Ruck und die mittlere Beschleunigung charakterisieren eine energieoptimale Fahrweise, bei der der Ruck nach Möglichkeit reduziert wird und Beschleunigungswerte tendenziell höher ausfallen.

Einfluss der Fahrschlauchbreite auf die Hybridmodi: Die durch die Strategie ausgewählten Hybridmodi sowie deren zeitliche Anteile an der gesamten Messung bestimmen maßgeblich den Kraftstoffverbrauch. In Abb. 7.15 sind die zeitlichen Anteile der Hybridmodi für drei Parameterkombinationen P_1, P_{16} und P_{22} dargestellt.

Dabei wird die Fahrschlauchbreite zwischen 1 und 10 m/s variiert. Bei allen Kombinationen nimmt der Anteil der möglichen Rekuperationsphasen (Reku) bei einer breiter werdenden Fahrschlauchbreite zu. Verzögerungsphasen können gezielt so ausgelegt werden, dass sie für die Randbedingungen der Rekuperation geeignet verlaufen.

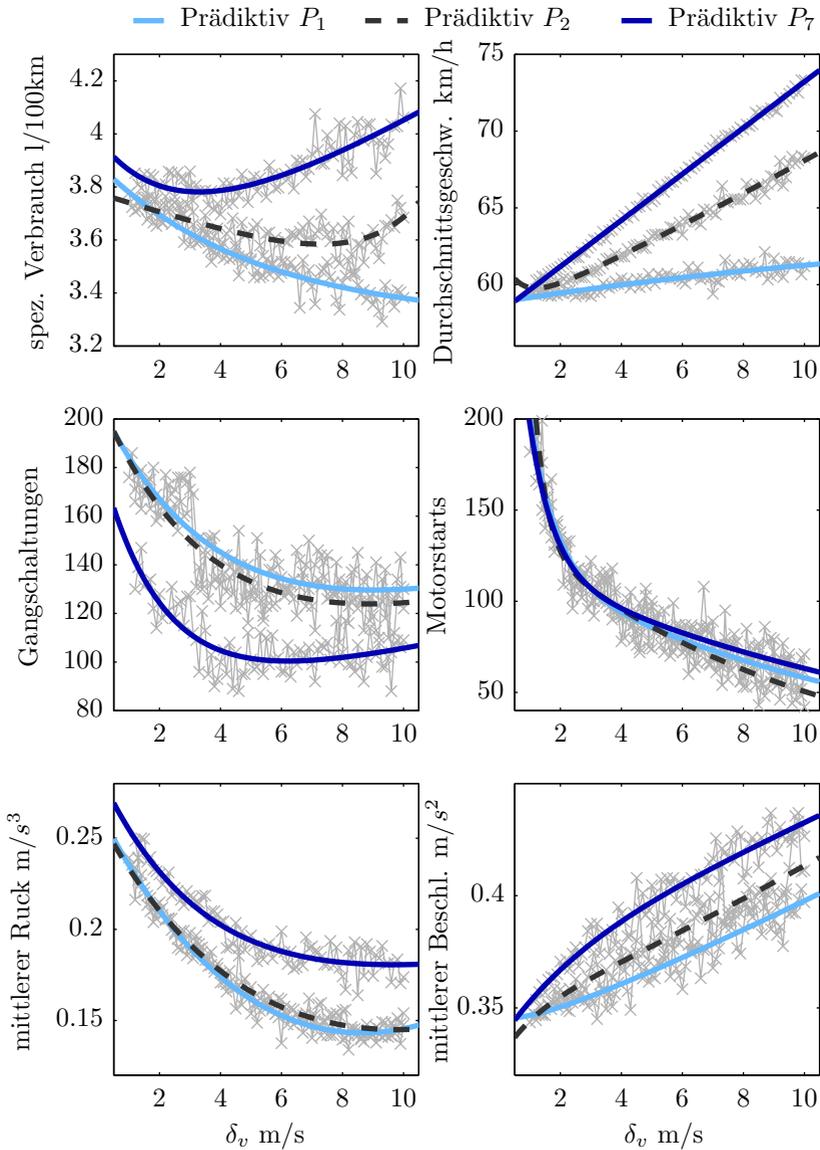


Abb. 7.14: Einfluss der Fahrschlauchbreite δ_v auf Verbrauch, Zeit (Geschwindigkeit) und Komfort (Anzahl dynamischer Vorgänge siehe Abschnitt 4.1.1 und Gesamtfahrzeugdynamik) dreier Parameterkombinationen

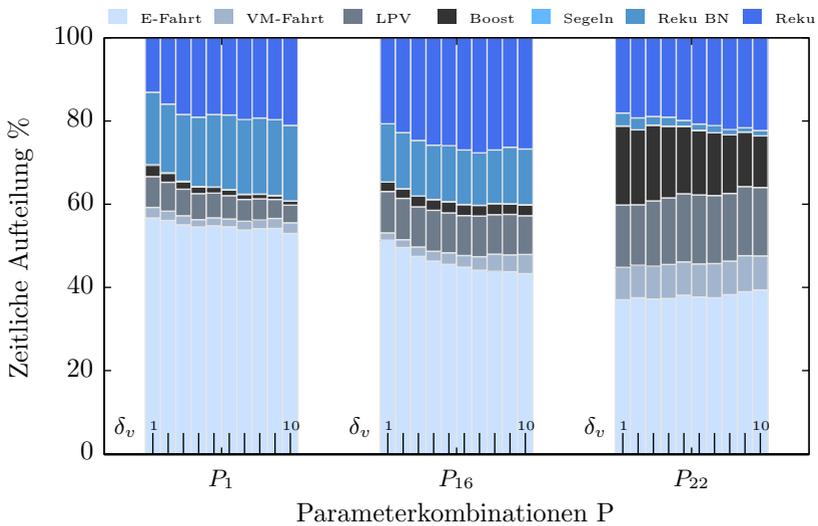


Abb. 7.15.: Einfluss der Fahrerschlauchbreite δ_v auf die zeitliche Verteilung der Hybridmodi für drei Parameterkombinationen

Während bei P_1 die Hybridmodi, bei denen der Verbrennungsmotor läuft, im Vergleich zu rein elektrischen Phasen gering ausfällt, nehmen diese bei der Gewichtung der Zeit (P_{16}, P_{22}) zu. Der Boost Modus, der bei P_1 von 2,75 % ($\delta_v = 1$ m/s) auf 0,96 % ($\delta_v = 10$ m/s) abfällt, nimmt bei P_{22} mit 19 % ($\delta_v = 1$ m/s) und 12,4 % ($\delta_v = 10$ m/s) einen deutlich größeren zeitlichen Anteil der Messung ein. Die Boost-Phasen Anteile nehmen unabhängig von der Parameterkombination bei zunehmender Fahrerschlauchbreite ab, während die Phasen der Lastpunktverschiebung (LPV) bei P_{22} von 15 % ($\delta_v = 1$ m/s) auf 16,5 % ($\delta_v = 10$ m/s) geringfügig zunehmen.

Betrachtet man alle Parameterkombination der Pareto-Front nach Abb. 7.2 lassen sich folgende Aussagen treffen (siehe Abb. 7.16):

- E-Fahrt Phasen nehmen bei größer werdenden Fahrerschlauchbreiten und einer stärkeren Gewichtung der Zeit (P_2 - P_{18}) ab.
- Längeres Rekuperieren ist durch einen breiteren Fahrerschlauch möglich.
- Sind nur die Zeit und der Komfort gewichtet (P_{19} - P_{22}), nehmen E-Fahrt und LPV Phasen zu.
- Die Bordnetz Rekuperation (Reku BN) belegt bei einer energetischen Gewichtung (P_1 - P_{18}) einen zeitlichen Anteil von durchschnittlich 18 %.

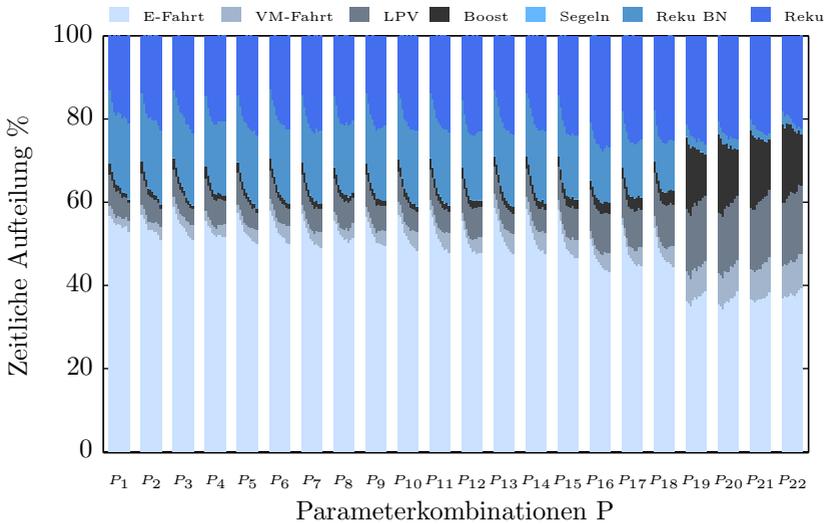


Abb. 7.16.: Einfluss der Fahrschlauchbreite auf die zeitliche Verteilung der Hybridmodi für alle Parameterkombinationen entlang der Pareto-Front

Dieser Anteil wird bei der höheren zeitlichen Gewichtung von der Boost-Phase übernommen (P_{19} - P_{22}).

Metamodellierung der Optimierung: Simulationsergebnisse mit unterschiedlicher Gewichtung der Kostenfunktion einer vorgegebenen Fahrschlauchbreite können funktional beschrieben werden. Dabei korreliert folgende Exponentialfunktion mit einem durchschnittlichen $\bar{R}^2 = 0,9359$ mit dem spezifischen Kraftstoffverbrauch über der Durchschnittsgeschwindigkeit \bar{v} (siehe Abb. A.6):

$$m_f(\delta, \bar{v}) = a \cdot e^{b \cdot \bar{v}} + c \cdot e^{d \cdot \bar{v}} \quad (7.5)$$

Jede Parameterkombination kann für unterschiedliche Fahrschlauchbreiten mit einer linearen Funktion beschrieben werden (siehe Abb. A.7). Während bei P_1 der spezifische Kraftstoffverbrauch bei steigender Durchschnittsgeschwindigkeit sinkt, steigt er bei zunehmender Gewichtung der Zeit in der Kostenfunktion an. Aufgrund der Parameterauslegung nach exemplarischen Fahrsituationen weichen die Verbrauchswerte der zeitoptimalen Gewichtung (P_{19} - P_{22}) von den restlichen Kombinationen ab und lassen dadurch ein Band an spezifischen Verbrauchswerten frei, die nicht abgedeckt sind.

Über die funktionale Beschreibung der Optimierung für die Stuttgart-Runde lässt sich für einen gewünschten spezifischen Kraftstoffverbrauch und eine gewünschte

Durchschnittsgeschwindigkeit eine Parameterkombination bei einer geeigneten Fahr-schlauchbreite bestimmen.

Als Beispiel soll im Folgenden die Kostenfunktion so parametrisiert werden, dass ein spezifischer Kraftstoffverbrauch von 5,5 l/100km bei einer Durchschnittsgeschwindigkeit von $\bar{v} = 70$ km/h das Ergebnis der Simulation ist.

In Abb. A.8 sind die Parameter der Kostenfunktion aus vorangegangenen Simulationen über dem spezifischen Verbrauch eingezeichnet. Durch ein Polynom 4. Ordnung können diese funktional abgebildet werden.

Für einen gewünschten Verbrauch von 5,5 l/100km setzen sich die Parameter für die Kostenfunktion wie folgt zusammen: $c_{\text{Energy}} = 3,47 \%$, $c_{\text{Time}} = 51,11 \%$, $c_{\text{Jerk}} = 13,31 \%$ und $c_{\text{Dyn}} = 32,11 \%$.

Das Ergebnis der Simulation der Stuttgart-Runde mit dieser Parametrisierung der Kostenfunktion ist in Abb. A.9 abgebildet. Dabei liegt der simulierte spezifische Verbrauch bei 5,65 l/100km (+2,69 %) mit einer Durchschnittsgeschwindigkeit von 69,97 km/h (-0,04 %). Die Auslegung der Kostenfunktion für ein gewünschtes Ergebnis der Simulation ist durch das Metamodell der Optimierung für diesen Fahrzyklus möglich.

7.1.3. Vergleich serieller und paralleler Optimierung

Bei den bisherigen Untersuchungen wurden die Fahrstrategie und die Energiemanagementstrategie in einer mehrdimensionalen Optimierung parallel berechnet. Dabei werden Wechselwirkungen zwischen den einzelnen Dimensionen wie Geschwindigkeit und Batterieladung durch eine höhere Komplexität berücksichtigt. Eine höhere Komplexität beinhaltet größere Speicherbelegungen sowie längere Rechenzeiten.

In einem weiteren, seriellen Ansatz wird die Optimierung in zwei aufeinander folgenden Schritten berechnet. Dabei wird zunächst die optimale Geschwindigkeit bestimmt und für diese in einem zweiten Schritt die optimale Energiemanagementstrategie berechnet. Um sowohl eine zeitliche als auch eine energetische Gewichtung in beiden Optimiererstufen zu gewährleisten, wird in der Berechnung der optimalen Geschwindigkeit die Leistung pro Zeit berücksichtigt, die am Rad anliegt und die die Radzugkraft beeinflusst. Die energetische Betrachtung des Antriebsstrangs sowie die Momentenaufteilung an den beiden Aggregaten erfolgt in der nachgelagerten Optimierung des Energiemanagements.

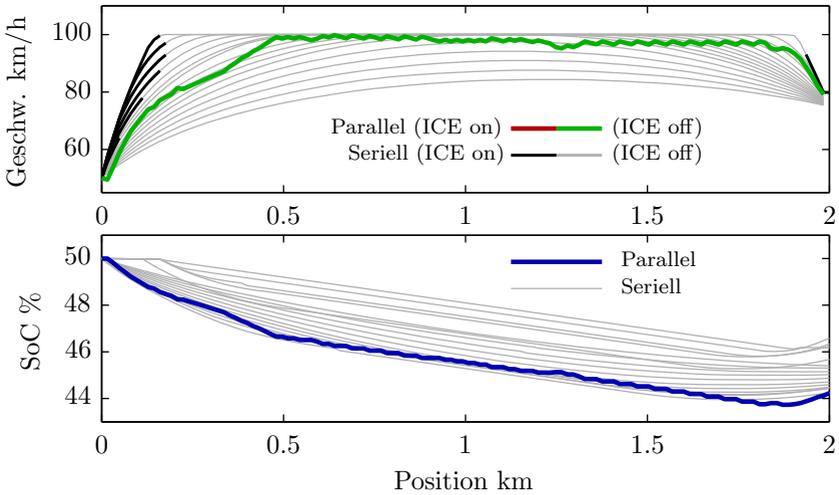


Abb. 7.17.: Vergleich unterschiedlich berechneter optimaler Strategien für eine längsdynamische Fahrsituation bei voller Batterie und Variation der Kostenfunktion

Die Kostenfunktion sowie deren Gewichtung ist entscheidend für den Verlauf der Strategien. Zur Reduktion dieser Einflüsse fließen bei der parallelen wie auch bei der seriellen Optimierung nur die Zeit (c_{Time}) und die Energie (c_{Energy}) als Gewichtungsfaktoren in die Kostenfunktion ein. Komfortkriterien werden allein durch maximale und minimale Beschränkungen eingehalten und nicht explizit bewertet.

Als Fahrsituation für den Vergleich der beiden Ansätze wird eine Beschleunigungsphase mit einer anschließenden Verzögerungsphase gewählt. In Abb. 7.17 sind Strategien der seriellen Optimierung (grau) für unterschiedliche Kostenfunktionen dargestellt sowie eine Variante der parallelen Optimierung (grün). Bei zunehmender Gewichtung der Zeit nähert sich die Geschwindigkeitsstrategie einer zeitlich optimalen Strategie mit hoher Durchschnittsgeschwindigkeit und starken Beschleunigungen und Verzögerungen an. Die Kapazität der Batterie erlaubt ein elektrisches Durchfahren der Fahrsituation bei einem Großteil der Strategien. Ist die Beschleunigung zu stark bzw. ist die Verzögerung durch Rekuperation nicht mehr möglich, wird der Verbrennungsmotor benötigt bzw. mechanisch gebremst (schwarz).

Bei der parallelen Optimierung können diese energetisch ungünstigen Phasen gezielt vermieden werden, indem in den Grenzen der E-Maschine beschleunigt wird sowie eine Verzögerungsphase an die Rekuperationsleistung angepasst wird. Die eingesetzte Energie bei der parallelen Optimierung unterscheidet sich geringfügig von der seriellen Berechnung, solange eine rein elektrische Fahrt möglich ist.

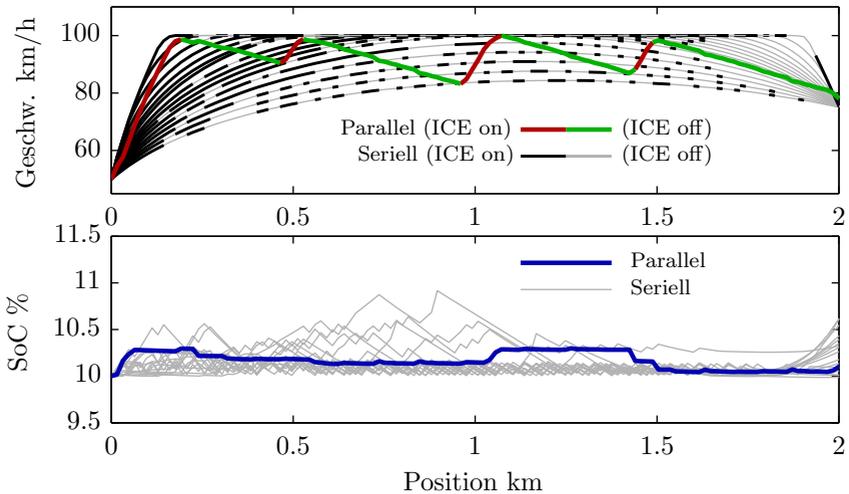


Abb. 7.18.: Vergleich unterschiedlich berechneter optimaler Strategien für eine längsdynamische Fahrsituation bei entladener Batterie und Variation der Kostenfunktion

Bei ausreichend großem Ladezustand der Batterie lässt sich durch eine geeignete Auslegung der Kostenfunktion das Ergebnis der seriellen Berechnung an das der parallelen Berechnung anpassen.

Betrachtet man dieselbe Fahrsituation bei leerer Batterie (siehe Abb. 7.18), so sind deutliche Unterschiede festzustellen: Bei der seriellen Optimierung hat die Änderung des Ladezustands der Batterie keine Auswirkungen auf die optimale Fahrstrategie, wodurch identische Geschwindigkeitsstrategien im Vergleich zu Abb. 7.17 resultieren. Die Beschleunigungsphase wird größtenteils mit der Verbrennungsmaschine bewältigt, ein häufiger Wechsel zwischen Phasen mit Verbrennungsmotor an (schwarz) und aus (grau) wird ausgewählt, da Dynamikwechsel nicht bestraft werden. Durch die Einschränkung der Geschwindigkeit wird eine Lastpunktverschiebung genutzt, um den Wirkungsgrad bei laufendem Verbrennungsmotor zu erhöhen.

Die parallele Optimierung wählt für diesen Extremfall eine Kombination aus mehreren steilen Beschleunigungsvorgängen und flach abfallenden Verzögerungen deren Abfolge die Form eines Sägezahns aufweist. Als Verzögerung wird vorzugsweise die Rekuperation zur Bordnetzerhaltung sowie Segeln gewählt und die Geschwindigkeit entsprechend angepasst. Die eingesetzte chemische Energie wird größtenteils in kinetische Energie umgesetzt und damit Verluste beim Aufladen der Batterie vermieden.

Bei voller Batterie wird die Fahrsituation fast vollständig elektrisch gefahren, sodass der Verbrauch größtenteils bei null Litern liegt. Dagegen wird bei leerer Batterie der Verbrennungsmotor zur Lastpunktverschiebung benötigt.

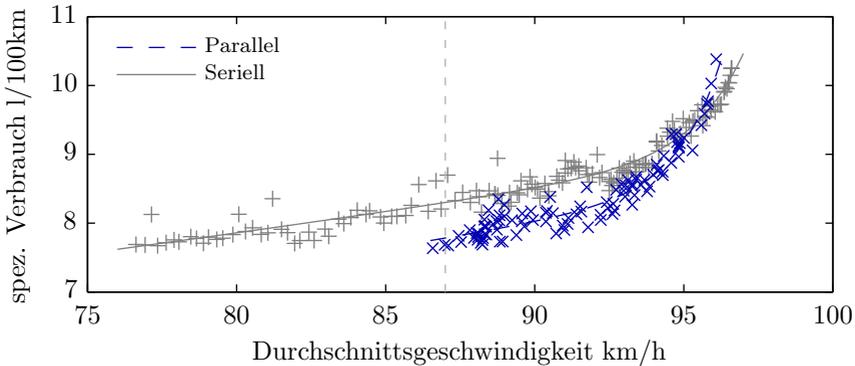


Abb. 7.19: Verbrauch unterschiedlich berechneter optimaler Strategien für eine längsdynamische Fahrsituation bei entladener Batterie

Der Verbrauch ändert sich durch die parallele Optimierung wie in Abb. 7.19 zu sehen. Durch ein Sägezahn Profil der Geschwindigkeit werden in der parallelen Optimierung Betriebspunkte ausgesucht, die den Kraftstoffverbrauch reduzieren können. Bei einer Durchschnittsgeschwindigkeit von 87 km/h können so im Mittel 6,23 % Kraftstoff in dieser Fahrsituation eingespart werden. Bei höheren Durchschnittsgeschwindigkeiten nimmt das Potenzial für die untersuchte Parametrierung ab.

Stuttgart-Runde: Ein Vergleich des kompletten Zyklus bestehend aus einzelnen Fahrsituationen wird in Abb. 7.20 gezeigt. Dabei werden bei der seriellen Optimierung die Parameter für die Fahrstrategie variiert. Phasen mit Verbrennungsmotor an, sind schwarz eingefärbt, rein elektrische Phasen grau dargestellt. Die Parametrierung der Kostenfunktion für die parallele Optimierung erfolgte für eine Fahrschlauchbreite von $\delta_v = 5$ m/s. Die Geschwindigkeitsstrategie mit dem Parametersatz P_1 für die parallele Optimierung ist abgebildet. Rein elektrische Phasen sind dabei grün und Phasen mit Verbrennungsmotor an rot abgebildet. Die SoC-Trajektorie der parallelen Optimierung zeigt ein vermehrtes elektrisches Fahren, das besonders in den Bereichen bis 10 km und zwischen 48 und 55 km im Vergleich zur seriellen Optimierung zu erkennen ist. Der zeitliche Anteil, in dem der Verbrennungsmotor nicht läuft, liegt bei der parallelen Optimierung mit der Parametrierung P_{19} bei 60 %, während in der seriellen Optimierung bei gleicher Durchschnittsgeschwindigkeit und gleichem Verbrauch nur 34 % erreicht wird.

Die Kostenfunktion in der seriellen Optimierung ist für den betrachteten Fall nicht flexibel genug, um wie in den einzelnen Fahrsituationen gezeigt an eine parallele Berechnung angepasst zu werden.

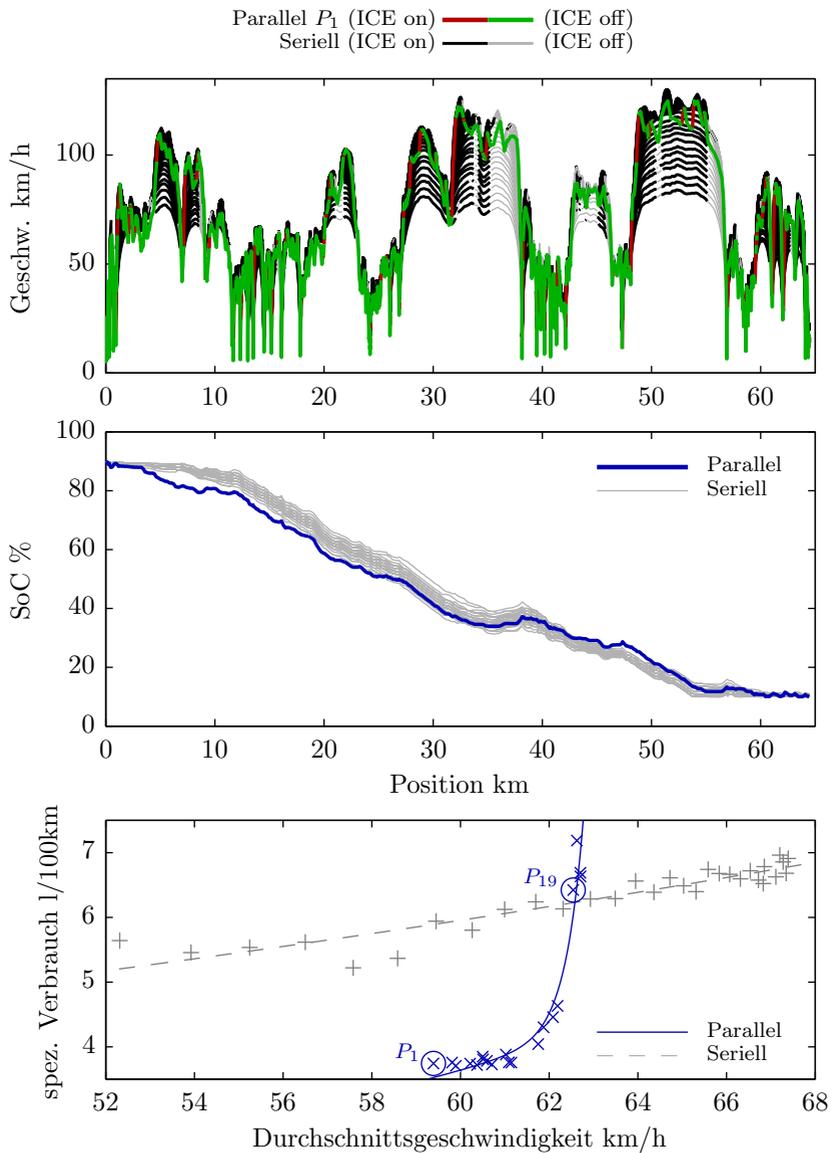


Abb. 7.20.: Vergleich seriell und parallel berechneter Strategien für unterschiedlich gewichtete Kostenfunktionen auf der Stuttgart-Runde. Rein elektrische Phasen sind grün bzw. grau sowie mit laufendem Verbrennungsmotor rot bzw. schwarz eingezeichnet.

Wird diese jedoch z. B. durch die Berücksichtigung von energetisch günstigen Verzögerungsphasen erweitert, kann die Strategie der seriellen Berechnung an die parallele Berechnung angenähert werden. Eine parallele Optimierung ermöglicht gerade auf einem Zyklus durch den zusätzlichen Freiheitsgrad und das Anpassen der Geschwindigkeitsstrategie an die Energiemanagementstrategie ein höheres Einsparpotenzial.

7.2. Fahrversuch und reale Verkehrsdaten

Für die Untersuchungen im Versuchsfahrzeug und mit realen Verkehrsdaten wird die LONGRANGE-Strategie herangezogen. Neben der in der Simulation verwendeten Stuttgart-Runde werden gerade für die Betrachtung von Verkehrsdaten mehrere längere Routen (Langstrecken) verwendet. Bei diesen dominiert der Autobahnanteil, sodass sie im Vergleich zur ausgeglichenen Stuttgart-Runde einen Kontrapunkt setzen.

Die Schnittstelle zur Hybridsteuerung im Fahrzeug ist in Abschnitt 6.2.4 beschrieben. Durch Einschränkungen der Schnittstelle kann nur die Basisstrategie über eine SoC-Vorgabe beeinflusst werden, weswegen eine Untersuchung zum Einsparpotenzial einer prädiktiven Strategie nur exemplarisch an einzelnen Messungen im Fahrzeug erfolgt.

Die Grundlage der Güte jeder prädiktiven Energiemanagementstrategie liegt in der Güte der präzierten Geschwindigkeit, aus der die Leistung am Rad und über eine Schaltstrategie die Leistung an den Aggregaten bestimmt werden kann. Durch gesetzliche Geschwindigkeitsbeschränkungen, die in digitalen Karten zur Verfügung stehen, kann eine Abschätzung getroffen werden, die eine Route durch ihre Straßenklassen charakterisiert. Für eine Prädiktion sind diese Daten zu ungenau. Gerade auf langen Strecken wird die Geschwindigkeit maßgeblich durch das Verkehrsaufkommen bestimmt, das je nach Uhrzeit stark von der Richtgeschwindigkeit abweichen kann.

7.2.1. Geschwindigkeitsstrategie

Bei der LONGRANGE-Strategie werden Verkehrsinformationen in der Geschwindigkeitsstrategie verarbeitet. Dabei wird je nach Verfügbarkeit und Güte der Information diese im Fahrschlauch berücksichtigt. Es wird zwischen drei Informationskategorien unterschieden: Referenzgeschwindigkeit, aktuelle Verkehrsflussgeschwindigkeit und modellierte Verkehrsflussgeschwindigkeit. Diese werden im Folgenden detailliert beschrieben.

Referenzgeschwindigkeit

Als *Referenzgeschwindigkeit* werden alle Geschwindigkeitsinformationen bezeichnet, die auf einem Straßensegment vorliegen, ohne Berücksichtigung der Verkehrslage. Diese können durch gesetzliche Maximal- und Richtgeschwindigkeiten festgelegt

sein und sind damit Teil der statischen Verkehrsdaten. Gesetzliche Geschwindigkeitsbeschränkungen können eine Vielzahl von Straßensituationen nicht abbilden. Eine enge Kurve auf einer Landstraße mit uneinsehbarem Kurvenausgang wird z. B. mit reduzierter Geschwindigkeit durchfahren, ohne dass ein Schild vorhanden ist. Ein weiteres Beispiel sind viele Straßensituationen in der Stadt. Enge Einbahnstraßen mit beidseitig parkenden Fahrzeugen und uneinsehbare Seitenstraßen werden unabhängig vom Verkehrsaufkommen in der Regel nicht mit 50 km/h durchfahren.

Verkehrsdatenlieferanten bezeichnen Referenzgeschwindigkeiten als „Free Flow“ und generieren diese Information aus aufgezeichneten Geschwindigkeiten in Zeiten in denen von einem reduzierten Verkehrsaufkommen ausgegangen wird wie z. B. bei Nacht. Somit wird durch die Referenzgeschwindigkeit eine Information bereitgestellt, die es erlaubt eine maximal gefahrene Geschwindigkeit für den jeweiligen Straßenabschnitt abzubilden.

Geschwindigkeitsinformationen liegen für jedes einzelne Straßensegment gemittelt vor. Befindet sich auf diesem Segment eine Kreuzung oder eine Ampel, so werden Standphasen mit Grün-Phasen gemittelt. Das Geschwindigkeitsniveau sinkt. Da diese Kreuzungssituationen in den statischen Kartenattributen vorliegen, können diese in der Berechnung des Fahrschlauchs berücksichtigt werden. In einem worst-case Szenario werden alle Stoppphasen berücksichtigt und so die maximal möglichen Anfahrvorgänge energetisch betrachtet. Die Berücksichtigung der Anhaltevorgänge führt zu einer Verbesserung der Verkehrsprädiktion besonders auf Stadtstraßen, wo Ampeln vermehrt vorkommen.

Aktuelle Verkehrsflussgeschwindigkeit

Die *aktuelle Verkehrsflussgeschwindigkeit* wird, wie in Abschnitt 3.5.3 beschrieben, durch eine Vielzahl einzelner Messungen von Verkehrsdatenlieferanten verarbeitet. Diese werden je nach Anbieter jede Minute aktualisiert. Im Versuchsfahrzeug werden alle 5 Minuten die aktuellen Geschwindigkeitsinformationen für eine eingegebene Route abgerufen. Die Länge eines Straßensegments beeinflusst die Genauigkeit der Information insofern, als dass auf diesem Segment die Informationen gemittelt werden. Die durchschnittliche Segmentlänge der untersuchten Messungen beträgt 743 m, wobei die minimale Segmentlänge 12 m beträgt [177]. Bundesstraßen und Bundesautobahnen sind durch ihre Durchdringung von aktiv genutzten Navigationsgeräten deutlich besser abgebildet als z. B. Überlandstraßen.

In Abb. 7.21 (oben) sind die aktuellen Geschwindigkeitsinformationen aus einer Messfahrt auf der Autobahn-Runde über Zeit und Strecke aufgetragen. Die Position des Versuchsfahrzeugs ist blau eingezeichnet. Zwischen der Position 7 und 20 km wird die Geschwindigkeit durch eine Stausituation (rot eingefärbt) stark reduziert, wodurch fast die Hälfte der Fahrt auf diesem Bereich der Route verbracht wird.

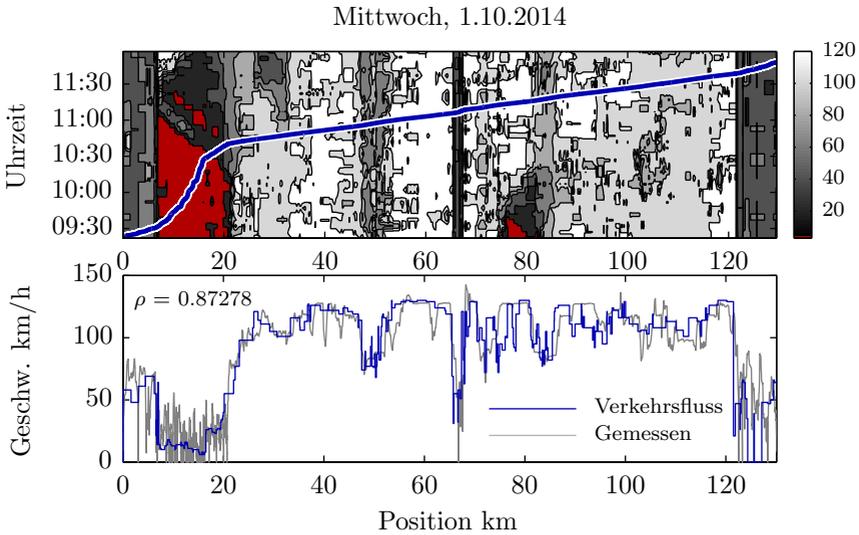


Abb. 7.21.: Aktuelle Verkehrsflussinformationen auf der Autobahn-Runde für eine Messung mit Stau (rot) sowie Position des Fahrzeugs über der Zeit und über der Geschwindigkeit

Die Staufront löst sich ab 10:30 Uhr zunehmend auf. Durch die lineare Verschiebung dieser Staufront ist ein Modellieren und dadurch Prädizieren des Stauverhaltens möglich.

In Abb. 7.21 (unten) ist die gefahrene Geschwindigkeit (grau) und die über die Schnittstelle abgerufene aktuelle Verkehrsflussgeschwindigkeit (blau) dargestellt. Die Anfahr- und Anhaltevorgänge im Stau sind deutlich zu erkennen und werden über die Geschwindigkeitsinformationen gemittelt wiedergegeben. Eine Korrelation der gefahrenen Geschwindigkeit mit der aktuellen Geschwindigkeit vom Backend ist zu erkennen.

Modellbasierte Verkehrsflussgeschwindigkeit

Auf Basis historischer Verkehrsdaten sind für Straßensegmente Geschwindigkeiten verfügbar, die als statistische Mittelwerte über eine Vielzahl von Messungen erfolgen. Die Durchschnittsgeschwindigkeit über einen gewissen Zeitraum ist für die Geschwindigkeitsstrategie zu ungenau, da zu viele Faktoren in einen Wert einfließen. Werden die historischen Daten nach Uhrzeit und Wochentag ausgewertet (siehe Abschnitt 3.5.3), so besteht die Möglichkeit, hohes Verkehrsaufkommen, das zu bestimmten Uhrzeiten durch den Berufsverkehr entsteht, abzuschätzen.

Dieses Verkehrsprädiktionsmodell ist in der Lage wiederkehrende Verkehrsdichten und dadurch entstehende Geschwindigkeitsreduktionen über der Zeit und dem Wochentag zu präzisieren. Bei durchschnittlichem Verkehrsaufkommen bilden die Schätzungen aus historischen Daten die Verkehrslage gut bis sehr gut ab. In Abb. 7.22 sind drei Messungen auf der Stuttgart-Runde am gleichen Tag dargestellt. Die Messungen erfolgten am Nachmittag ①, am frühen Abend ② und in der Nacht ③. Die Modellbasierten Geschwindigkeiten werden für den Wochentag sowie die genaue Startuhrzeit der Messungen bestimmt und sind jeweils in blau zu der gefahrenen Geschwindigkeit (grau) eingezeichnet.

In Messfahrt ① liegt ein moderater Nachmittagsverkehr vor, der über das Prädiktionsmodell sehr gut abgebildet werden kann. Die Prädiktion ist meist konservativ abgeschätzt, sodass die gefahrene Geschwindigkeit diese vereinzelt übersteigt. In Messfahrt ② ist das Verkehrsaufkommen deutlich erhöht. Es kommt vereinzelt zu Staubildung und zäh fließendem Verkehr (Kreise). Dieser kann über aktuelle Verkehrsflussinformationen besser abgebildet werden. Das Prädiktionsmodell weicht an diesen Stellen teilweise stark von der gefahrenen Geschwindigkeit ab. Die Korrelation sinkt im Vergleich zu ① deutlich. In der nächtlichen Messfahrt ③ ist fast kein Verkehr vorhanden. Die Geschwindigkeit kann frei gewählt werden. Trotz Verbesserung der Korrelation zwischen gemessener und prädikzierter Geschwindigkeit sind Abweichungen vorhanden, die durch energieoptimale Verzögerungsphasen (Kreise) zu erklären sind. Modellbasierte Verkehrsflussgeschwindigkeiten dienen der Verbesserung der statischen Referenzgeschwindigkeiten, können aber reduzierte Geschwindigkeiten bei Staus durch die in dieser Arbeit vorliegenden Prädiktionsmodelle nicht abbilden.

Kombinierte Verkehrsdaten

Die Geschwindigkeiten aus Echtzeitverkehrsdaten korrelieren gut mit gemessenen Geschwindigkeiten, sind jedoch durch ihre Stufenform nicht direkt für eine Leistungsprädiktion geeignet. Werden diese Informationen in der Optimierung einer Geschwindigkeitsstrategie verwendet, entsteht durch die Berücksichtigung des Fahrzeugmodells und geeigneter Kostenfunktionen ein Geschwindigkeitsverlauf, der zum einen sehr nahe an die gemessene Geschwindigkeit herankommt und zum anderen optimale Dynamikeigenschaften aufweist.

Für eine weitere Messfahrt sind die verfügbaren Geschwindigkeitsinformationen einander gegenübergestellt (siehe Abb. 7.23). Eine Stausituation bei 28 km wird von der Referenz- und Modellbasierten Geschwindigkeit nicht abgedeckt. Die Aktuelle Verkehrsflussgeschwindigkeit ist wiederum nur auf Autobahnabschnitten präzise und weicht auf den anderen Straßenklassen deutlich ab. Da je nach Straßenklasse unterschiedliche Informationsgüten vorherrschen, werden unterschiedliche Informationen zu einer kombinierten Verkehrsinformation zusammengefügt. Im Versuchsfahrzeug steht das Verkehrsprädiktionsmodell nicht zur Verfügung.

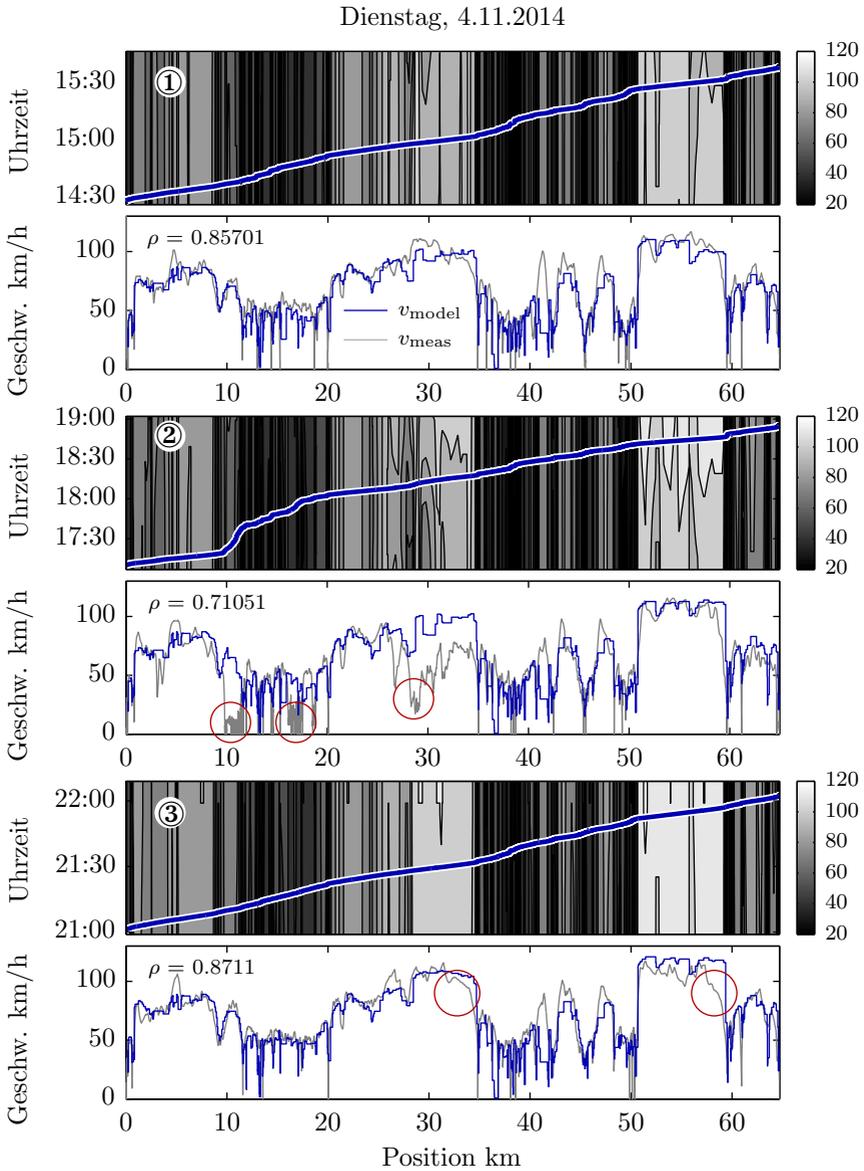


Abb. 7.22.: Modellbasierte Verkehrsflussinformationen auf der Stuttgart-Runde für drei Messungen am selben Tag sowie Position des Fahrzeugs über der Zeit und der Geschwindigkeit

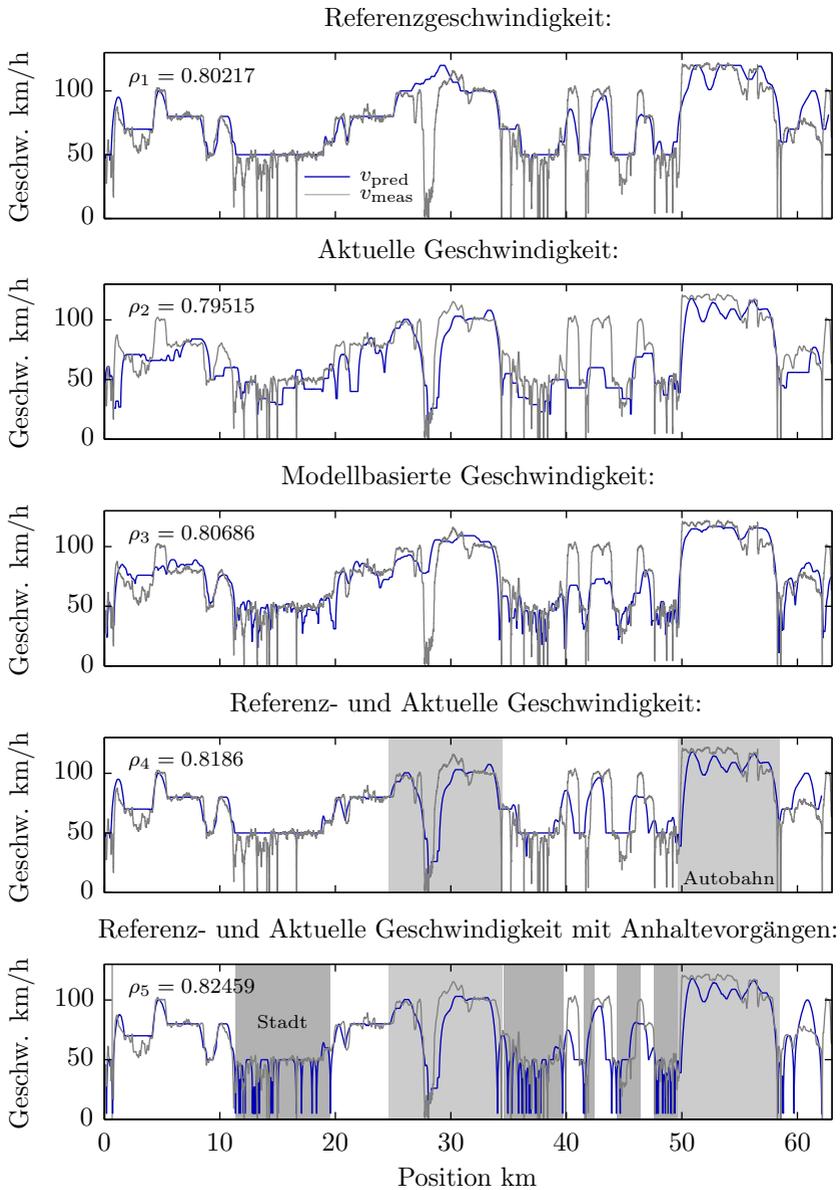


Abb. 7.23.: Geschwindigkeitsstrategien auf Basis von verfügbaren Verkehrsflussinformationen kombiniert auf unterschiedlichen Abschnitten der Stuttgart Runde nach [177]

Deswegen werden die Referenzgeschwindigkeit und aktuelle Verkehrsflussgeschwindigkeit kombiniert (4. Grafik in Abb. 7.23). In den beiden Autobahnabschnitten der Stuttgart-Runde werden die aktuellen Geschwindigkeiten verwendet, während auf den anderen Abschnitten die Referenzgeschwindigkeit als obere Geschwindigkeitsbegrenzung in den Fahrschlauch der Optimierung einfließt. Durch Hinzunahme von allen möglichen Anhaltevorgängen aus der digitalen Karte wird die Geschwindigkeitsstrategie besonders auf den Stadtstraßen an die gemessene Geschwindigkeit angepasst. Der empirische Korrelationskoeffizient der Strategie auf Basis der Referenzgeschwindigkeit $\rho_1 = 0,802$ wird auf $\rho_5 = 0,825$ verbessert. Die Dynamik auf unterschiedlichen Straßentypen ist somit in der Berechnung der Geschwindigkeitsstrategie abgebildet.

7.2.2. Leistungsprädiktion

Die prädizierte Radleistung ist das Produkt der Zugkraft mit der Geschwindigkeitsstrategie. Während die Geschwindigkeit maßgeblich durch den Verkehr und das Fahrverhalten dominiert ist, fließen in die Zugkraft Fahrzeugeigenschaften sowie unterschiedliche Fahrwiderstände (siehe Abschnitt 2.2.1) ein. Je besser diese Einflussfaktoren präzisiert werden können, desto besser ist die Leistungsprädiktion am Rad.

In Abb. 7.24 (oben) ist die prädizierte Radleistung mit der aus der gemessenen Geschwindigkeit berechneten Radleistung auf einer Messung der Stuttgart-Runde dargestellt.

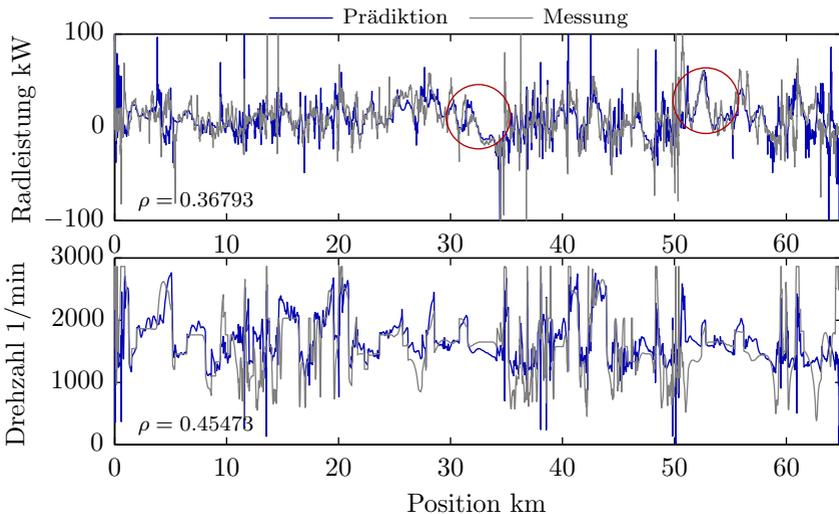


Abb. 7.24.: Prädizierte und gemessene Radleistung und Getriebeeingangsdrehzahl auf der Stuttgart-Runde ohne Längsregelung

Durch große lokale Abweichungen (Peaks) fällt der Korrelationskoeffizient mit $\rho = 0,368$ schlecht aus. Einzelne Phasen sind jedoch gut abgebildet. Die Rekuperationsphasen am Ende der beiden Autobahnabschnitte (Kreise) stimmen sehr gut überein. Für die Energiemanagementstrategie ist die Leistung relevant, die am Getriebeeingang gefordert wird. Die Drehzahl an dieser Stelle wird durch einen Sensor genau bestimmt. In Abb. 7.24 (unten) ist die gemessene Getriebeeingangsdrehzahl sowie die durch die Geschwindigkeitsstrategie und Schaltstrategie prädierte Drehzahl aufgetragen. Durch Abweichungen in der Geschwindigkeitsstrategie und der Vereinfachungen im Fahrzeugmodell weichen die beiden Verläufe lokal voneinander ab. Das Drehzahlniveau wird jedoch auf die komplette Strecke sehr gut prädiert.

Wird die Geschwindigkeit durch eine Längsregelung vorgegeben, kann die Leistungsprädiktion am Rad verbessert werden (siehe Abb. A.10). Die Getriebeeingangsdrehzahl ist über längere Phasen deutlich glatter im Vergleich zu einer Messfahrt, bei der der Fahrer über das Gaspedal die Geschwindigkeit vorgibt. Durch Ein- und Ausscheren vorausfahrender Verkehrsteilnehmer, die in der Prädiktion nicht berücksichtigt werden weichen Prädiktion und gemessene Werte gerade bei mehrspurigen Straßenabschnitten stark voneinander ab. Bei der Messfahrt mit aktiver Längsregelung ist ein höheres Verkehrsaufkommen vorhanden, wodurch der Korrelationskoeffizient auf $\rho = 0,37$ absinkt.

7.2.3. Regelungsverhalten

Die LONGRANGE-Strategie wird zyklisch aktualisiert. Es wird vom aktuellen Fahrzeugzustand aus gerechnet. Änderungen der aktuellen Verkehrsflussgeschwindigkeit fließen auf den Autobahnabschnitten in die Geschwindigkeitsstrategie ein. Durch die eingeschränkten Stellmöglichkeiten der Hybridsteuerung hat die Frequenz der Neuberechnung Auswirkungen auf die SoC-Trajektorie. In Abb. 7.25 sind zwei Messfahrten dargestellt. Dabei wird die LONGRANGE-Strategie für unterschiedliche Updateraten neu berechnet. Bei einer Aktualisierung alle 30 s ist die Hybridsteuerung durch das Umschalten zwischen vorgegebenen Kennfeldern zu träge um einer SoC-Vorgabe zu folgen. Der aktuelle Fahrzeugzustand fließt schneller in eine Neuberechnung ein, als dass die Hybridsteuerung der Vorgabe folgen kann. Dies führt zu einem Abdriften der SoC-Trajektorien hin zu einer schnelleren Entladung der Batterie. Wird die Strategie nur alle 300s berechnet, folgt die Regelung der Vorgabe deutlich besser.

Die Frequenz der Regelung beeinflusst neben der Hybridsteuerung die Geschwindigkeitsstrategie. Die Geschwindigkeitsinformationen auf den Autobahnanteilen variieren stärker, da hier aktuelle Verkehrsflussdaten verwendet werden. Diese Abschnitte sind sensible gegenüber aktuellen Verkehrsänderungen, auch wenn diese noch nicht relevant sind. Durch eine niedriger gewählte Updaterate kann dieser Effekt reduziert werden.

Auf der Autobahn-Runde wird ein größerer Streckenanteil durch aktuelle Verkehrsflussinformationen beeinflusst.

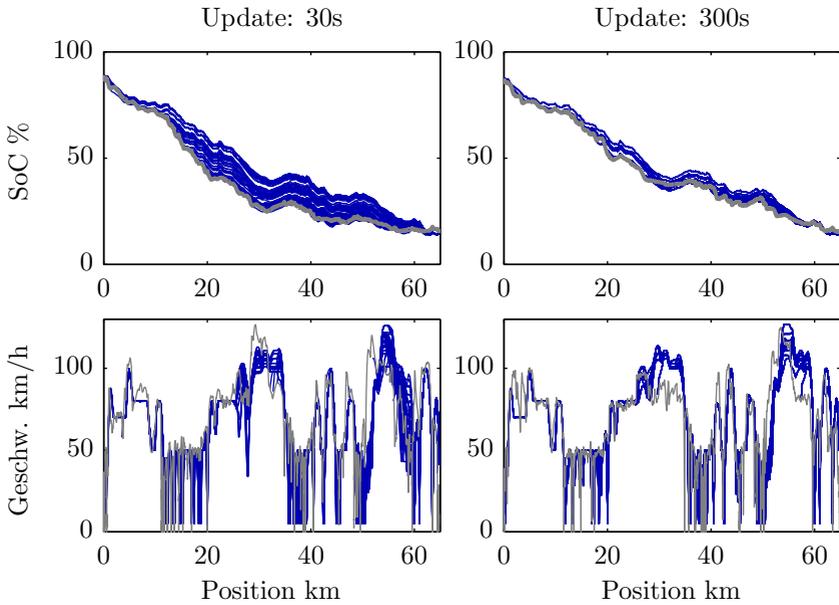


Abb. 7.25.: Neuberechnung der LONGRANGE-Strategie für unterschiedliche Updateraten nach [177]

Für die in Abb. 7.26 gezeigte Messfahrt, in der die ersten Kilometer durch ein Stauverhalten (Rot) gekennzeichnet sind, wird das Neuberechnen der Strategien mit aktuellen Verkehrsinformationen verdeutlicht. In einer Updaterate von 300s sind alle berechneten Geschwindigkeitsstrategien über der Zeit und Position aufgetragen (oben). Drei der Strategien sind exemplarisch herausgegriffen (unten). Auf den ersten Kilometern wird in der Geschwindigkeitsstrategie der aktuelle Stau sowie ein Stau bei etwa 80 km berücksichtigt. Die Geschwindigkeitsstrategie ① passt diese Geschwindigkeit an das Geschwindigkeitsniveau bei 80 km an. Bis zum Erreichen der ersten 20 km der Strecke vergeht eine Stunde und der anfänglich berücksichtigte Stau bei 80 km hat sich aufgelöst. Die Geschwindigkeitsstrategie in ② wird bei 80 km nicht mehr reduziert. Eine Geschwindigkeitsreduktion, die durch eine Baustelle bei 50 km verursacht wurde, wird weiterhin berücksichtigt. Lokale Einschränkungen aus ② bei 87 und 100 km sind bei der Berechnung der Strategie in ③ nicht mehr relevant.

In Abb. 7.27 sind die Energiemanagementstrategien für die Messfahrt auf der Autobahn-Runde mit den Geschwindigkeitsstrategien und den gemessenen Größen an vier Positionen dargestellt. Hybridphasen sind bei der gemessenen Geschwindigkeit schwarz und bei der präzierten Geschwindigkeit rot gekennzeichnet.

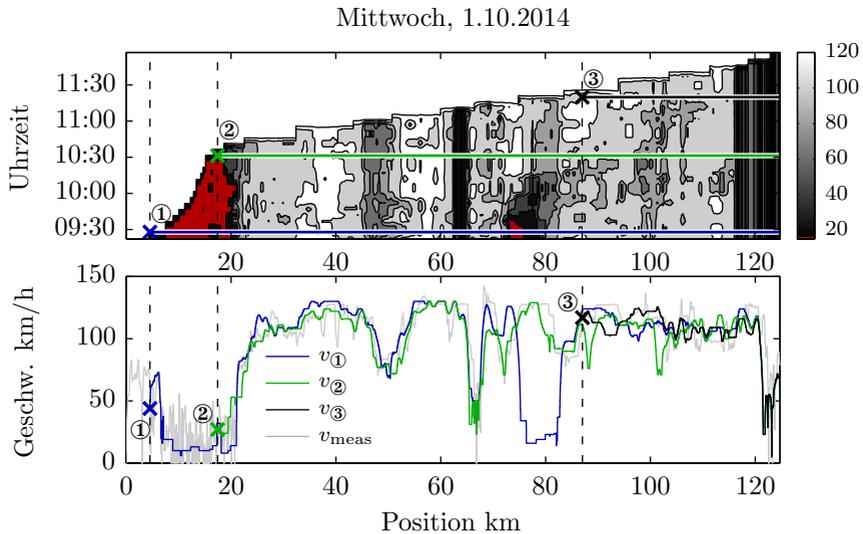


Abb. 7.26.: Aktualisierung der Geschwindigkeitsstrategien auf Basis aktueller Geschwindigkeitsinformationen in einer Messung auf der Autobahn-Runde

Rein elektrische Phasen sind bei der gemessenen Geschwindigkeit grau und bei der prädizierten grün eingefärbt. Die Prädiktion in ① schätzt das elektrische Fahren im Stau deutlich höher ab, sodass der SoC am Ende des Staus um 10 % niedriger ausfällt als bei dem gemessenen Wert bei Position 20 km. Bei einer Neuberechnung im Stau ② gleichen sich gemessene und prädizierte Batterieladungsstrategie an. Der zweite Stau bei 80 km hat dabei wenig Auswirkungen auf die Prädiktion, weil die Energie, die benötigt wird um aus der Stauphase heraus zu beschleunigen, fast vollständig bei der Verzögerung in die Stauphase rekuperiert werden kann. Der SoC wird durch die Prädiktion vor dem Stau nur leicht um 6 % bei 70 km angehoben. Trotz ähnlichen Geschwindigkeitsverläufen weicht der SoC bei der Prädiktion, die in ③ berechnet wird, um bis zu 16 % ab (siehe Kreis). Dies ist durch lokal verschiedene Verkehrsdynamik zu erklären. Die Prädiktion in ④ stimmt sehr gut mit der tatsächlichen Energiemanagementstrategie auf den letzten 30 km überein.

Anhand der gemessenen Werte ist zu erkennen, dass in Verzögerungsphasen weitgehend rekuperiert wird. Beschleunigungsphasen sowie hohe Geschwindigkeiten werden hybridisch durchfahren. Der prädizierte Kraftstoffverbrauch wird entlang der Strecke unterschätzt, wobei die anfänglich prädizierte Strategie um 20 % von der gemessenen Strategie $m_{f,meas}$ abweicht (siehe Abb. 7.28). Dies kann durch eine deutlich höhere Fahrdynamik im realen Verkehr erklärt werden.

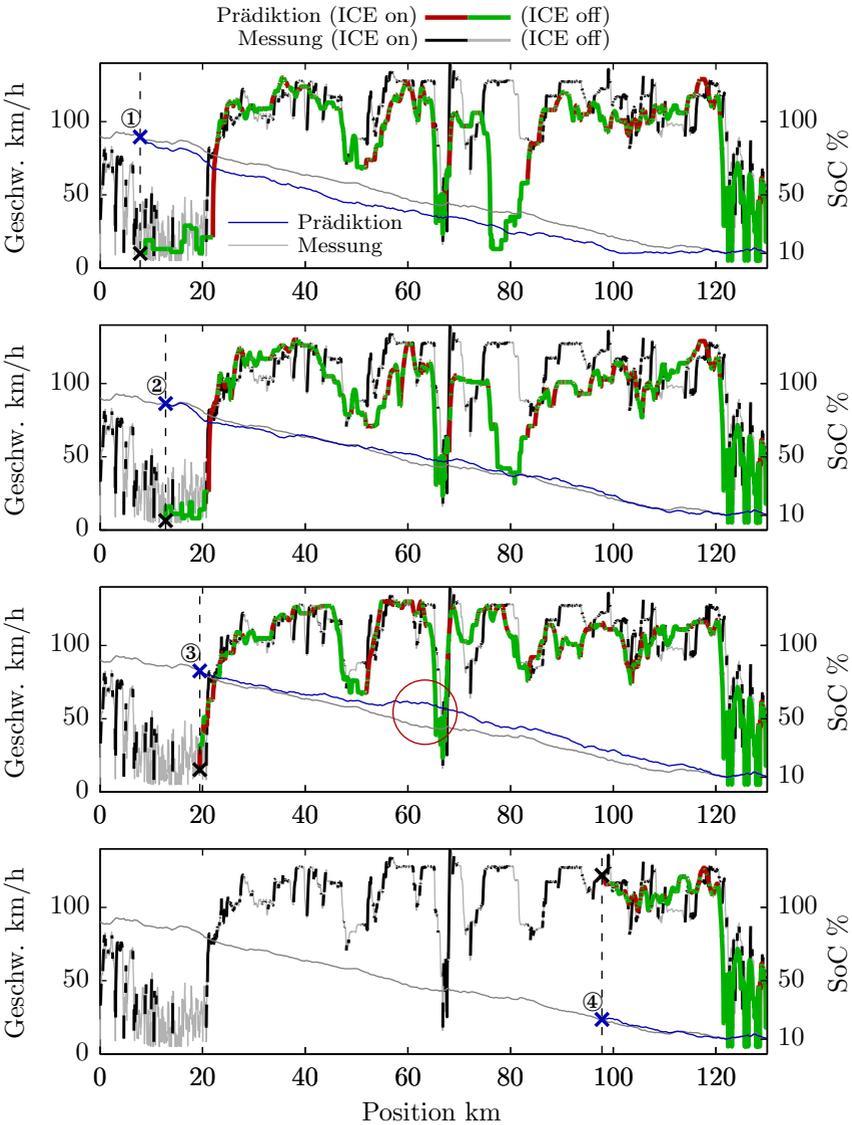


Abb. 7.27: Aktualisierung der Energiemanagementstrategie auf Basis aktueller Geschwindigkeitsinformationen in einer Messung auf der Autobahn-Runde

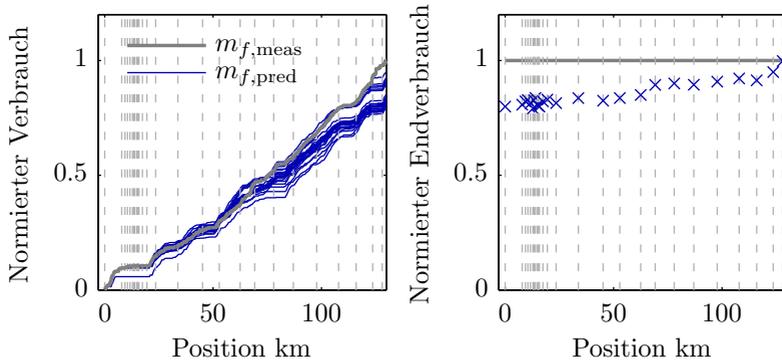


Abb. 7.28.: Prädizierter Kraftstoffverbrauch einzelner Strategien normiert auf den Gesamtverbrauch entlang einer Messung auf der Autobahn-Runde

Die Prädiktion einer Stausituation mit vielen Anfahrvorgängen kann durch eine auf die Geschwindigkeit modulierte Schwingung weiter verbessert werden.

7.2.4. Potentialanalyse

Umfangreiche Testfahrten waren im Versuchsfahrzeug aufgrund von technischen Problemen nicht möglich. Daher wurden nur einzelne Fahrten auf der Stuttgart-Runde durchgeführt, bei denen die Längsregelung nicht aktiv war und somit die Geschwindigkeit vom Fahrer frei gewählt wurde. Für einen Vergleich eines prädiktiven Energiemanagements mit der heuristischen Basisstrategie wurden je fünf Messfahrten durchgeführt. Die Messfahrten mit der Basisstrategie erfolgten im August während der Sommerferien, die der prädiktiven Strategie im November 2014.

In Abb. 7.29 sind die SoC- und Geschwindigkeitsverläufe der Messfahrten dargestellt. Dabei folgen die SoC-Trajektorien der Basisstrategie dem charakteristischen CDCS Verlauf, während die prädiktiven SoC-Trajektorien der kontinuierlichen Entladung im Sinne einer Blending Strategie folgen.

In der Messfahrt vom 4.11.2014 um 17:13 Uhr ist ein deutlich erhöhtes Verkehrsaufkommen vorhanden, sodass es bei 10 km, 18 km und im Autobahnabschnitt zwischen 25 und 35 km zu zäh fließendem Verkehr bis hin zu Stau mit Stillstand kommt. Der Stau bei 10 km dauert ca. 30 Minuten (siehe Abb. 7.21 ②), wodurch die Batterie stark entladen wird. Der SoC-Verlauf dieser Messfahrt weicht durch die Stauphase von den anderen Messfahrten ab.

In Abb. 7.30 sind die spezifischen Verbrauchswerte der einzelnen Messfahrten über der Durchschnittsgeschwindigkeit dargestellt. Während alle Messfahrten mit der Basisstrategie bei Durchschnittsgeschwindigkeiten zwischen 50 und 60 km/h liegen, gibt es bei den Messfahrten der prädiktiven Strategie zwei Ausreißer.

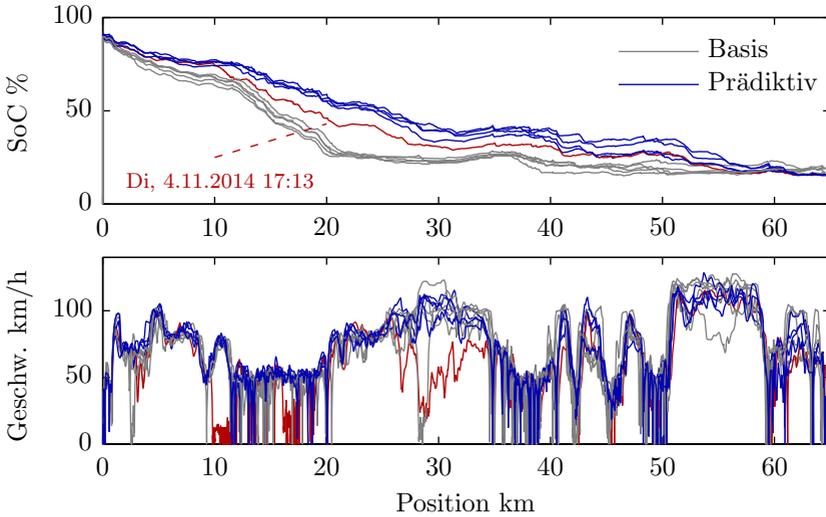


Abb. 7.29.: Reale Messfahrten auf der Stuttgart-Runde mit Basisstrategie und prädiktiver Strategie

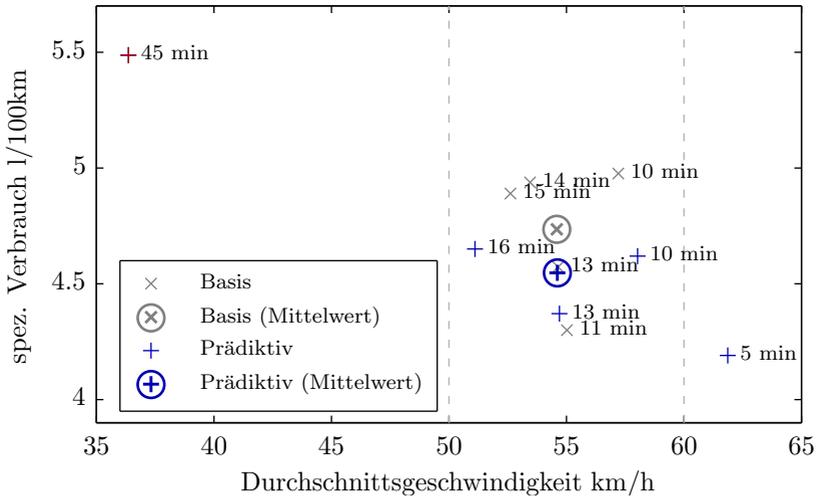


Abb. 7.30.: Verbrauchswerte und aufsummierte Zeiten (Standphasen und niedrigen Geschwindigkeiten bis 25 km/h in Minuten) für alle betrachteten Messfahrten

Die Fahrt mit erhöhtem Verkehrsaufkommen resultiert in einem Verbrauch von 5,49 l/100km und liegt damit 15,9 % über dem durchschnittlichen Verbrauch der Messungen der Basisstrategie. Bei einer Nachtfahrt (siehe Abb. 7.21 ③), bei der der Verkehr zu vernachlässigen ist und dadurch auch Ampelphasen kürzer geschaltet werden, wird mit der prädiktiven Strategie ein Verbrauch von 4,19 l/100km erreicht. Dies stellt eine Verbraucheinsparung von 11,5 % bei gleichzeitiger Erhöhung der Durchschnittsgeschwindigkeit um 13,33 % dar.

Die für die Stadt- und Autobahnanteile typischen Standphasen und niedrigen Geschwindigkeiten bis 25 km/h weichen in den vorgestellten Extremsituationen stark von den Werten der übrigen Messfahrten ab. Ohne Verkehrsaufkommen bei Nacht betragen diese Phasen aufsummiert nur 5 min in der Messfahrt, während sie im Schnitt bei Messungen mit der Basisstrategie bei 13 min liegen.

Bei der Messfahrt mit erhöhtem Verkehrsaufkommen beträgt die gesamte Zeit der Standphasen und niedrigen Geschwindigkeiten 45 min. Der Bordnetzverbrauch sowie der elektrische Vortrieb in den Anfahrvorgängen benötigen Energie, die auf der restlichen Fahrt nicht weiter eingesetzt werden kann, wodurch der erhöhte Verbrauch zu erklären ist. Werden nur die Messfahrten der prädiktiven Strategie in Betracht gezogen, die zur Basisstrategie eine vergleichbare Durchschnittsgeschwindigkeit und Standphasenzeit aufweisen, so wird der Kraftstoffverbrauch im Durchschnitt um 3,97 % reduziert [177].

Die wenigen Messfahrten erlauben keine allgemeinen Aussagen, sondern zeigen lediglich eine Tendenz der Verbrauchseinsparung mit der prädiktiven Strategie auf. Der Einfluss der Verkehrslage wird gerade durch die beiden Extremsituationen mit und ohne Verkehr herausgestellt.

Verkehrsprädiktionsmodell

Das Potenzial einer Verkehrsprädiktion soll anhand aufgezeichneter Verkehrsdaten, welche die aktuellen Geschwindigkeiten abbilden, auf der Stuttgart-Runde untersucht werden. Dazu wird auf Echtzeitgeschwindigkeitsinformationen, wie in Abschnitt 3.5.3 beschrieben, zurückgegriffen, die minutengenau für eine gesamte Woche vor den Pfingstferien vom 1.-7. Juni 2014 vorliegen. Das Verkehrsprädiktionsmodell ist in Abschnitt 3.5.3 beschrieben.

Bei der Untersuchung wird die LONGRANGE-Strategie im Abstand von einer Stunde für die aktuellen Geschwindigkeitsinformationen (TrafficFeed) und die modellbasierten Geschwindigkeitsinformationen (IQ-Routes) ausgeführt. Die Geschwindigkeits- und SoC-Trajektorien aller Berechnungen auf Basis der aktuellen Geschwindigkeiten sind in Abb. 7.31 dargestellt.

Während die Geschwindigkeiten auf allen Streckenabschnitten stark variieren, ändern sich die Batterieladungsstrategien über der Position nur um maximal 10 %.

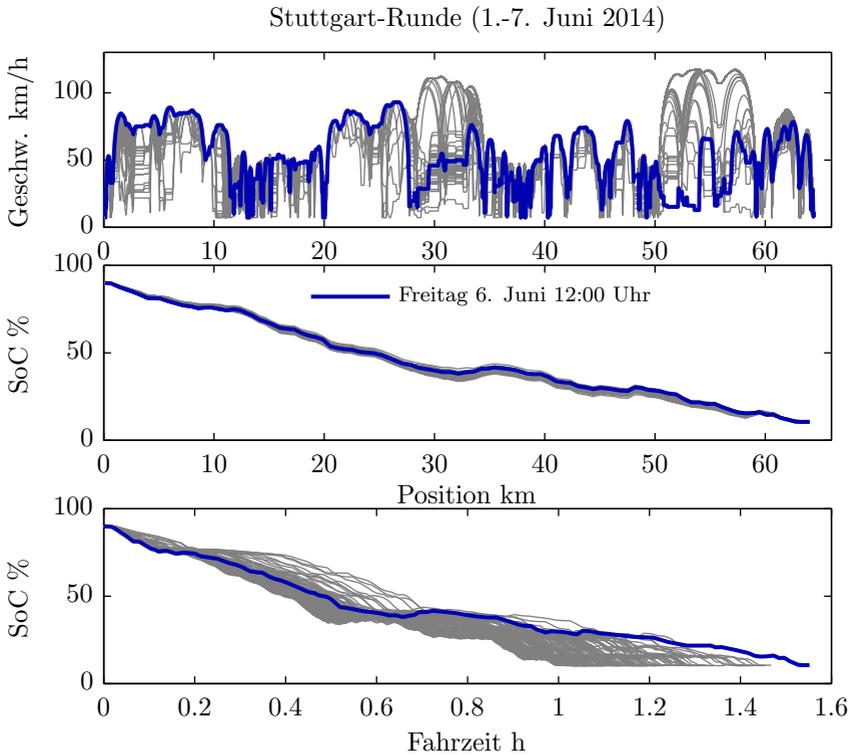


Abb. 7.31.: LONGRANGE-Strategien, berechnet im Abstand von einer Stunde über einem Zeitraum von einer Woche auf Basis aktueller Geschwindigkeitsinformationen

Die Fahrzeit variiert zwischen einer und 1,6 Stunden und beeinflusst somit die benötigte Energie je Wochentag und Uhrzeit.

Wird der Kraftstoffverbrauch jeder Berechnung über der gesamten Woche betrachtet, sind an den Werktagen Spitzenwerte zu erkennen, die im Vergleich zu Fahrten in der Nacht um bis zu 16,8 % abweichen können (siehe Abb. 7.32). Die Verbrauchswerte der Berechnungen auf Basis der historischen Daten liegen im Schnitt unter denen der TrafficFeed. Die hohe Verkehrsbelastung durch Berufsverkehr ist bei den Fahrzeiten deutlich zu erkennen. Das Prädiktionsmodell bildet diese hohen Auslastungen morgens und am frühen Nachmittag gut ab. Die tatsächlichen Auslastungen werden jedoch übertroffen (siehe Abb. 7.32).

Freitag der 6. Juni und Samstag der 7. Juni weichen deutlich vom prädizierten Verhalten ab, was auf den anstehenden Ferienstart zurückzuführen ist.

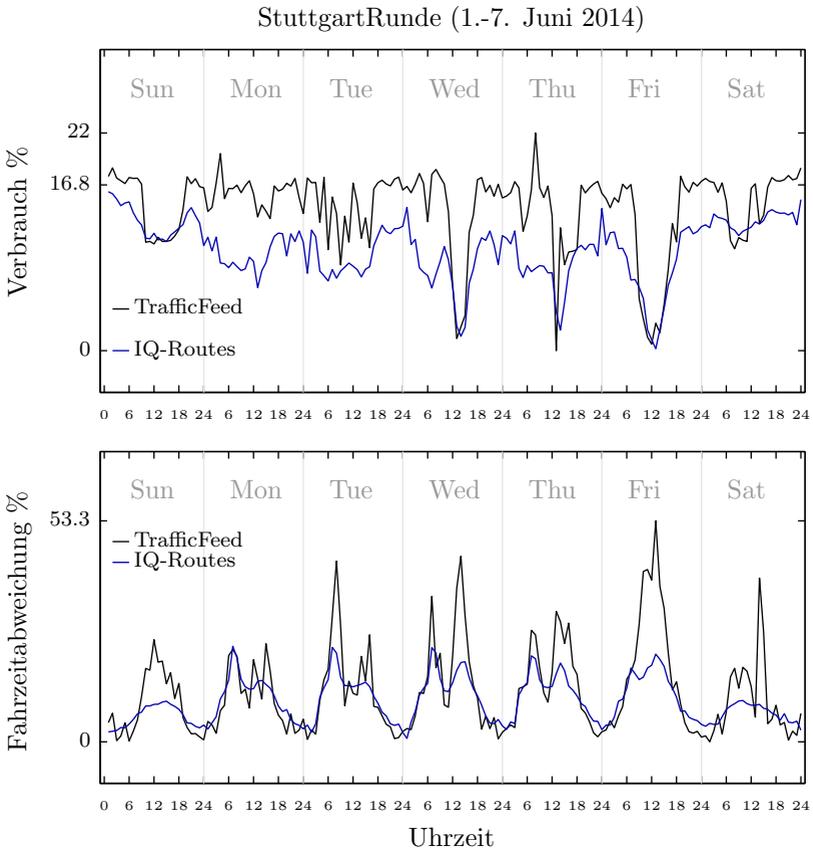


Abb. 7.32.: Verbrauch und Fahrzeit je Uhrzeit und Wochentag

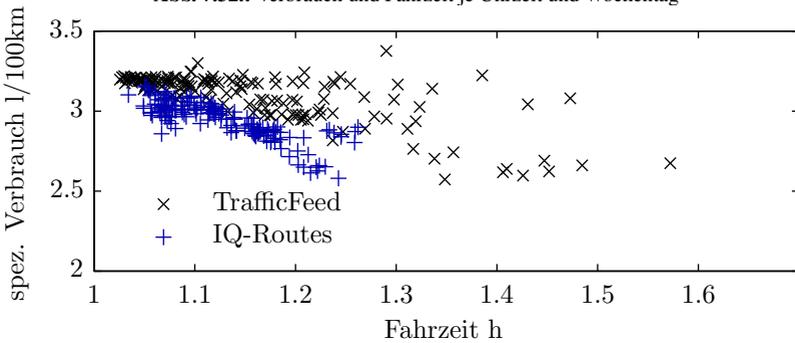


Abb. 7.33.: Verbrauchswerte und Fahrzeiten des Verkehrsprädiktionsmodells

Die maximale Verkehrsauslastung auf der Stuttgart-Runde wird am Freitag den 6. Juni bei einem Fahrtantritt um 12 Uhr erreicht. Die Fahrzeit ist um 53 % erhöht und der Verbrauch sinkt, da die Durchschnittsgeschwindigkeit im Vergleich zu anderen Tagen der Woche niedrig ausfällt. Auch am Samstag ist das Verkehrsaufkommen aufgrund der Ferien am Nachmittag deutlich höher als prädictiert.

Ein linearer Zusammenhang zwischen Kraftstoffverbrauch und benötigter Fahrzeit ist in Abb. 7.33 für die einzelnen Berechnungen zu erkennen. Der Gradient des prädictierten Verbrauchs ist flacher als der tatsächliche Verbrauch. Das Verkehrsprädictionsmodell bildet wiederkehrende Verkehrsmuster gut ab, ist jedoch durch aktuelle Verkehrsinformationen zu ergänzen, um auf einen kurzen Horizont die Prädiction zu verbessern.

7.2.5. Langstreckenanalyse

Ein Plug-in Hybridfahrzeug hat im Gegensatz zu einem Elektrofahrzeug eine deutlich größere Gesamtreichweite. Auch wenn der Vorteil der zum Fahrtbeginn geladenen elektrischen Energie bei zunehmender Routenlänge stetig abnimmt, (siehe Abschnitt 7.10) ermöglicht die prädictive Strategieplanung gerade auf bergigen Strecken eine Reduktion des Kraftstoffverbrauchs.

Das Aufzeichnen aktueller Verkehrsinformationen auf interessanten Routen ermöglicht ein Testen der LONGRANGE-Strategie unter realen Verkehrsbedingungen. Zeitaufwendige Messfahrten können dadurch gerade bei langen Strecken vermieden werden. Eine statistische Absicherung ist durch eine beliebige Neuberechnung zu verschiedenen Tageszeiten und Wochentagen möglich.

Einfluss Höhenprofil

Für die Untersuchung des Einflusses des Höhenprofils auf die Strategie wird die Strecke von Ulm nach Bozen (Italien) gewählt (siehe Langstrecke Ulm-Bozen Abb. A.5). Sie zeichnet sich durch eine Länge von fast 350 km sowie Gebirgsstraßen aus, wodurch das Höhenprofil gerade auf dem Fernpass (B179) stark variiert. Die aktuellen Verkehrsflussinformationen wurden vom 21. September bis zum 4. Oktober 2014 in beide Richtungen aufgezeichnet.

Die Verbrauchswerte je Wochentag und Uhrzeit für die Strecke Ulm-Bozen sind in Abb. A.11 und A.12, für die Gegenrichtung Bozen-Ulm in Abb. A.13 und A.14 dargestellt. Die maximale Abweichung im Verbrauch zwischen Tag- und Nachtfahrten liegt bei 18,2 % und fällt mit Höhenprofil tendenziell höher aus. Ein Vergleich der Berechnungen mit und ohne Höhenprofil zeigt das Rekuperationspotential für die Strecke:

Tab. 7.4.: Einfluss des Höhenprofils auf den Verbrauch

Abweichung: Verbrauch	Ulm-Bozen		Bozen-Ulm	
	1. Woche 21.-27.9	2. Woche 28.9.-4.10.	1. Woche 21.-27.9	2. Woche 28.9.-4.10.
Tag / Nacht ohne Höhenprofil	11,3 %	14,8 %	16,8 %	13 %
Tag / Nacht mit Höhenprofil	13,3 %	18,2 %	18,1 %	16 %
Rekuperationpotential	7,8 %	7,6 %	-1,6 %	-1,5 %

Das Höhenprofil weist von Ulm nach Bozen deutlich mehr Abschnitte mit Gefällen auf, wodurch der Verbrauch mit Höhenprofil berechnet im Durchschnitt um 7,8 und 7,6 % gesenkt wird. In der Gegenrichtung von Bozen nach Ulm fällt durch das Höhenprofil ein Mehrverbrauch von 1,5 % an. Neben dem Höhenverlauf fließt die Lageenergie in diese Ergebnisse ein, denn Bozen liegt 232 m über N.N., während Ulm bei 479 m über N.N. liegt.

Wird die Batterieladungsstrategie mit und ohne Höhenprofil betrachtet, variieren die Strategien über einen größeren Bereich verglichen mit Strategien der Stuttgart-Runde (1. Woche siehe Abb. 7.34 und Abb. 7.35, 2. Woche siehe Abb. A.15 und Abb. A.16). Der Einfluss der Geschwindigkeiten auf die Batterieladungsstrategie ist deutlich zu erkennen. Während bei der Stuttgart-Runde mit einem Fünftel der Streckenlänge ein kontinuierliches Entladen zu erkennen ist und nur in Rekuperationsphasen die Batterie geladen wird, werden bei einer längeren Strecke auch längere Ladephasen als optimal ausgesucht. Vor allem in den Berechnungen ohne Höhenprofil sind diese zu erkennen. Da durch den großen Anteil an hohen Geschwindigkeiten und einer begrenzten elektrischen Reichweite auf der Autobahn der Verbrennungsmotor vorzugsweise ausgewählt wird, stellt die Lastpunktverschiebung und das damit verbundene Laden der Batterie an vielen Stellen eine aus energetischer Sicht optimale Strategie dar, obwohl diese Ladeweise verlustbehaftet ist.

Das Rekuperationspotential aufgrund eines Höhenprofils verändert die optimalen Strategien deutlich, sodass bei der Ulm-Bozen Strecke alle Strategien bei ca. 160 km⁷⁹ um 30 % nachladen und die Batterie bis 260 km vollständig entladen. Bei der Rückfahrt Bozen-Ulm wird auf den ersten 75 km vermehrt elektrisch gefahren. Zwischen 75 und 120 km befindet sich ein Gefälle von ca. 600 Höhenmetern. Hier wird in allen Strategien die Batterie um fast 50 % vollgeladen⁸⁰.

Rekuperationsphasen werden in allen Strategien genutzt um elektrische Energie in die Batterie zu laden. Deutlich zu erkennen sind diese Phasen bei der Betrachtung der Gradienten jeder SoC-Strategie über der Position (siehe Abb. 7.36).

⁷⁹ Dies entspricht dem Gefälle auf dem letzten Abschnitt des Fernpasses

⁸⁰ Ein Überhitzen der E-Maschine und dadurch bedingte reduzierte Motorleistung (Derating) wurde in der Berechnung nicht berücksichtigt

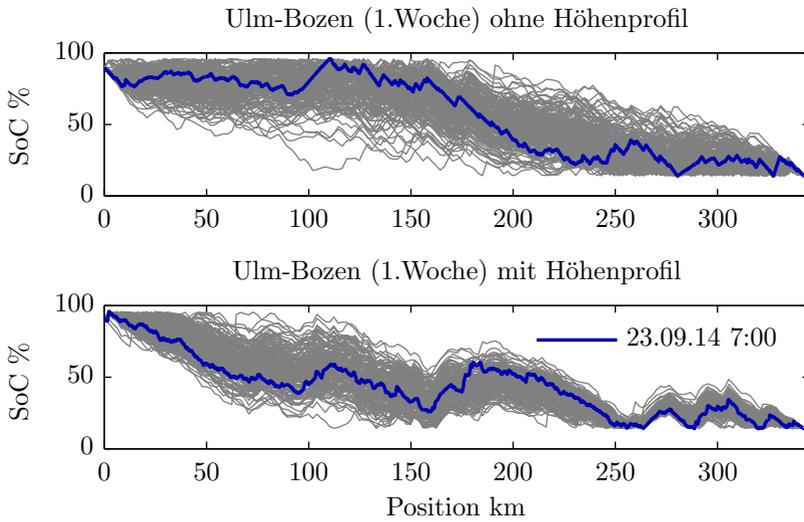


Abb. 7.34.: LONGRANGE-Strategie auf der Langstrecke Ulm-Bozen

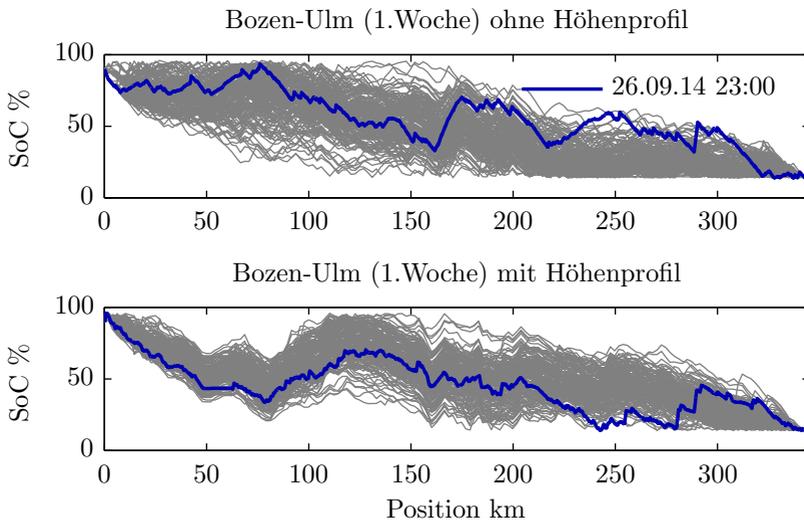


Abb. 7.35.: LONGRANGE-Strategie auf der Langstrecke Bozen-Ulm

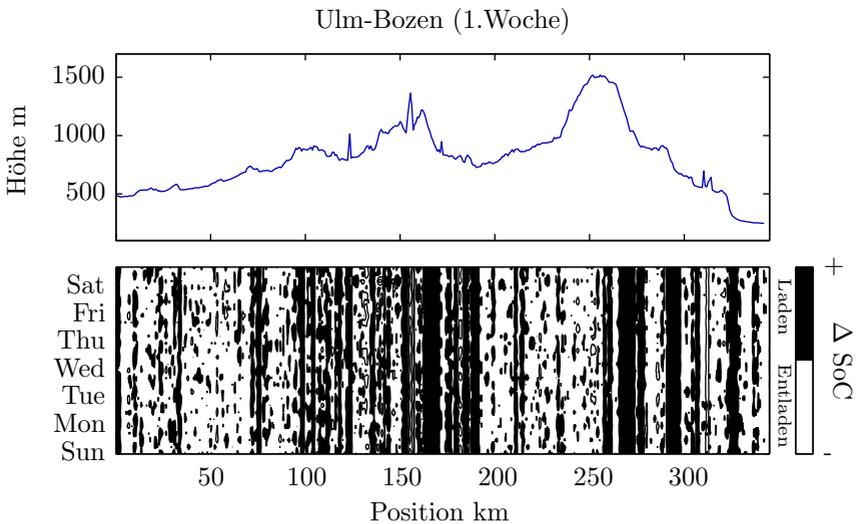


Abb. 7.36.: LONGRANGE-Strategie auf der Langstrecke Ulm-Bozen

Wird in Ladephasen mit positivem ΔSoC (schwarz) und Entladephasen mit negativem ΔSoC (weiß) unterschieden, lassen sich positionsabhängige Muster erkennen, die in jeder Strategie über die erste Woche betrachtet identisch verlaufen.

Diese senkrechten schwarzen Balken, die sich über die gesamte Woche erstrecken, befinden sich an Positionen, bei denen das Höhenprofil starkes Gefälle aufweist. Der Wert der Gradienten an diesen Positionen ist über alle Strategien hinweg vergleichbar.

Reisezeit

Der Einfluss der Fahrzeit kann auf langen Strecken durch hohes Verkehrsaufkommen stark variieren. Im Rahmen von Untersuchungen auf mehreren Autobahnen in Mitteleuropa werden Geschwindigkeitsstrategien stündlich für aufgezeichnete aktuelle Verkehrsflussinformationen berechnet und damit Messfahrten mit unterschiedlichen Startzeitpunkten auf diesen Routen simuliert.

Die Reisezeit variiert dabei je nach Route und betrachteter Woche zwischen maximalen 30 % bis hin zu 70 % Fahrzeitabweichung (siehe Abb. A.17, Abb. A.18, Abb. A.19 und Abb. A.20). Die Strecke Basel-Frankfurt wurde dabei über einen Zeitraum von 5 Wochen betrachtet:

Während die Fahrzeit im Durchschnitt um 15,3 % von der schnellsten Reisezeit abweicht, sind vor allem in Woche 5 große zeitlich begrenzte Abweichungen zu unterschiedlichen Wochentagen zu erkennen.

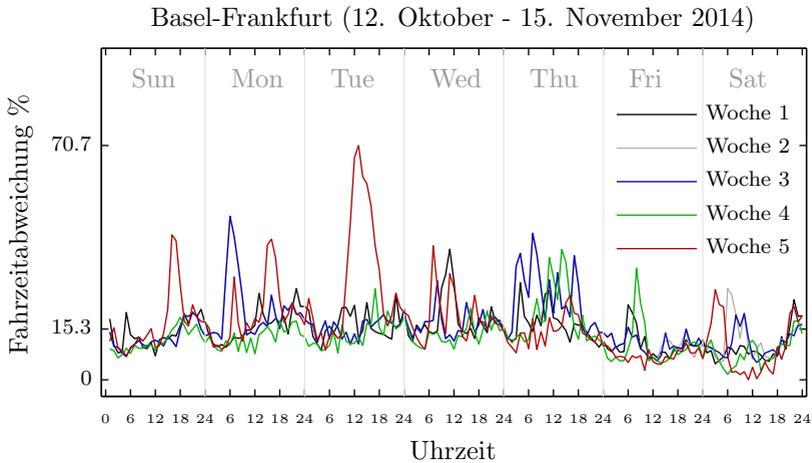


Abb. 7.37.: Reisezeiten auf der Langstrecke Basel-Frankfurt

Diese haben Einfluss auf den Verbrauch wie in Abb. 7.38 (oben) zu sehen. Je kürzer die Fahrzeit, desto höher die Durchschnittsgeschwindigkeit und desto höher der Verbrauch. Mit zunehmender Fahrzeit nimmt der Verbrauch linear ab und wird bei einer Fahrzeitverlängerung von einer halben Stunde um 21 % reduziert. Wird die Fahrzeit weiter erhöht auf 4,5 Stunden, reduziert sich der Verbrauch um weitere 3 %.

Werden alle Geschwindigkeitsstrategien nur verbrennungsmotorisch (ICE only) ohne elektrischen Antrieb und Rekuperation berechnet (siehe Abb. 7.38 (unten)), steigt der Verbrauch im Mittel über alle Messungen um 28,4 %. Der hohe Verbrauch bei minimaler Fahrzeit fällt linear bei zunehmender Fahrzeit um 13,6 % bei einer Fahrzeitverlängerung von einer halben Stunde ab. Bei niedrigen Geschwindigkeiten und dadurch längerer Fahrzeit nimmt der Verbrauch um 6,6 % wieder zu. Der schlechte Wirkungsgrad des Verbrennungsmotors bei niedrigen Momenten trägt entscheidend zu diesem Ergebnis bei.

Die Vorteile eines Hybridantriebs, der im Falle niedriger Geschwindigkeiten durch hohes Verkehrsaufkommen elektrische Energie effizient einsetzen kann, ist damit auch auf Langstrecken mit großen Autobahnanteilen gezeigt. Ergebnisse weiterer Strecken sind im Anhang zu finden (Abb. A.21, Abb. A.22, Abb. A.23 und Abb. A.24).

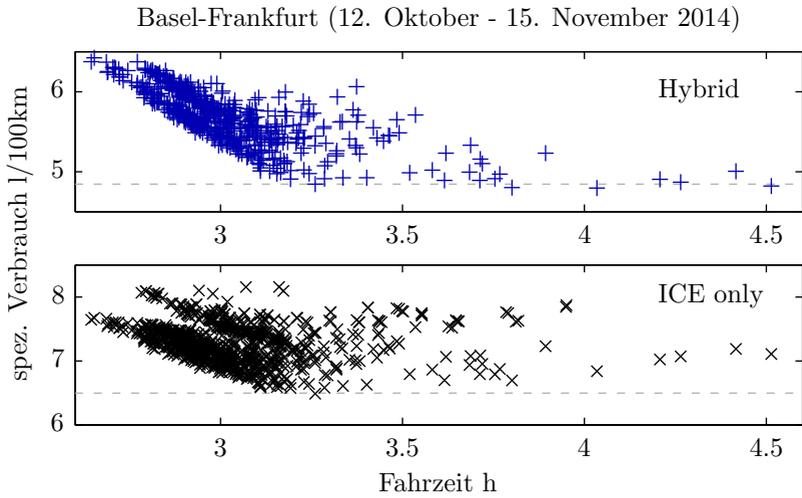


Abb. 7.38.: Verbrauchswerte und Fahrzeiten auf der Langstrecke Basel-Frankfurt für hybride Energiemanagementstrategien (Hybrid) und rein verbrennungsmotorischer Betrieb (ICE only)

8. Zusammenfassung und Ausblick

Hybridfahrzeuge kombinieren die Vorteile eines Verbrennungsmotors mit denen einer E-Maschine und können so trotz eines höheren Gewichts des Antriebsstrangs den Kraftstoffverbrauch senken. Ein Energiemanagement für koordinierte Energie- und Leistungsflüsse im Antriebsstrang ist notwendig und kann je nach Anforderung unterschiedlich ausgeprägt sein. Die Planung und Vorgabe von Steuergrößen wird Energiemanagementstrategie genannt.

Im Bereich der Fahrerassistenzsysteme wird auf dem Weg zum autonomen Fahren die Längsführung in Form eines adaptiven Tempomaten von einigen Herstellern angeboten. Unter Gewährleistung von Sicherheit und Komfort besteht die Möglichkeit, die Geschwindigkeit und Schaltstrategie energetisch optimal vorzugeben. Diese Vorgabe kann allgemein als Fahrstrategie bezeichnet werden.

Das Ziel dieser Arbeit ist die Entwicklung eines Fahrerassistenzsystems, das Fahrstrategien und Energiemanagementstrategien vereint und dadurch ein zeit- und energieoptimales Steuern des Fahrzeugs ermöglicht. Dazu ist die Modellierung des Antriebsstrangs sowie der Umgebung und der Strecke bis zum Reiseziel notwendig.

Der komplexe Antriebsstrang eines parallelen Hybridfahrzeugs wird in Funktionen modelliert, die ein schnelles Berechnen aller relevanten energetischen Vorgänge im Fahrzeug ermöglichen. Dynamische Vorgänge, wie das Wiederstartverhalten des Verbrennungsmotors, werden separat untersucht. Einzelne Funktionen des Fahrzeugmodells werden mit aufgezeichneten Messsignalen validiert.

Sowohl die Fahrstrategie als auch die Energiemanagementstrategie werden in dieser Arbeit optimiert. Die Dynamische Programmierung wird als numerisches Lösungsverfahren für die Optimalsteuerungsprobleme verwendet. Es garantiert Optimalität im Rahmen des formulierten Problems. Während es in der Literatur aufgrund des exponentiellen Anstiegs der Rechenzeit und des Speichers bei mehrdimensionalen Zustandsräumen nur für Systeme niedriger Ordnung und meist in der Simulation verwendet wird, kann in dieser Arbeit eine Echtzeitfähigkeit auch bei höheren Dimensionen erreicht werden. Das energie- und zeitoptimale Fahrerassistenzsystem vereint zwei Zielsetzungen: Zum einen sollen alle verfügbaren Informationen entlang der Strecke bis zum Fahrtziel in der Optimierung berücksichtigt werden. Zum anderen soll die Optimierung im Fahrzeug Teil der Längsregelung sein und somit das maximale Potenzial auch bei multikriterieller Zielsetzung darstellen.

Eine Modellbasierte Prädiktive Regelung wird eingesetzt, die durch Modellwissen über das Fahrzeug und die Strecke zu jedem Zeitpunkt eine optimale Steuergrößenfolge liefert.

Der Informationsgehalt bis zum Fahrtziel ist zu groß, um in einer Zykluszeit von wenigen Millisekunden optimale Ergebnisse in einer Modellbasierten Prädiktiven Regelung zu berechnen. Des Weiteren unterscheiden sich die Informationen sehr durch ihre Aktualisierungsrate sowie ihre Genauigkeit und Relevanz im Bezug auf die aktuelle Position des Fahrzeugs.

Um eine echtzeitfähige Regelung zu erreichen, sind die folgenden zwei Maßnahmen notwendig, die in dieser Arbeit entwickelt werden:

- Parallelisierung der Berechnung der Strategien für unterschiedliche Prädiktionshorizonte durch eine mehrstufige, zeitlich kaskadierte Modellbasierte Prädiktive Regelung
- Reduktion der Rechenzeit und des benötigten Speichers für die Optimierung durch verschiedene methodische Erweiterungen in der Dynamischen Programmierung

Für die mehrstufige Modellbasierte Prädiktive Regelung werden drei Stufen gewählt, deren Bezeichnung die Länge des jeweiligen Prädiktionshorizont widerspiegelt: SHORTRANGE, MIDRANGE und LONGRANGE. Während die SHORTRANGE-Strategie eine Längsregelung in wenigen Millisekunden garantiert, betrachtet die LONGRANGE-Strategie die gesamte Fahrtstrecke bis zum Ziel und ermöglicht so eine optimale Ausnutzung der vor der Fahrt aufgeladenen elektrischen Energie in einem Plug-in Hybridfahrzeug.

Es werden verschiedene Methoden zur Echtzeitoptimierung mittels Dynamischer Programmierung betrachtet und bewertet. Der Fokus liegt dabei auf der Reduktion und Eingrenzung möglicher Strategien auf relevante Strategien, um so die Rechenzeit und den benötigten Speicher zu reduzieren und die Optimalität der Ergebnisse zu gewährleisten. Es werden iterative, heuristische sowie approximative Methoden sowie deren Kombination vorgestellt und miteinander verglichen. Mithilfe der Iterativen Dynamischen Programmierung wird die Rechenzeit einer optimalen Fahrstrategie in einer Untersuchung um 84 % sowie der Speicher um 92,3 % bei identischem Ergebnis reduziert. In einer anderen Untersuchung werden Methoden der Approximierten Dynamischen Programmierung verwendet, um eine optimale Energiemanagementstrategie zu berechnen. Bei einer Genauigkeitsabweichung von 0,31 % zu einer optimalen Referenzstrategie wird die Rechenzeit um 89,78 % reduziert, während der benötigte Speicher nur noch 0,028 % der ursprünglichen Methode entspricht. Algorithmen reduzieren somit den Rechenspeicher. Um eine mehrdimensionale Optimierung zu ermöglichen, wird das Boxen-Prinzip entworfen. Dabei wird die Anzahl einzelner Berechnungen durch lokale Optimierungen und modellbasierte Vorauswahl interessanter Bereiche im kontinuierlichen Zustandsraum so reduziert, dass eine echtzeitfähige Optimierung realisiert werden kann.

Diese Methode wird für die MIDRANGE-Strategie und einen fünfdimensionalen Zustandsraum verwendet, der sowohl relevante Größen für die Fahrstrategie als auch für die Energiemanagementstrategie beinhaltet. Über eine Kostenfunktion, die unterschiedliche Gütemaße für die Zeit, die Effizienz sowie den Komfort beinhaltet, ist eine multikriterielle Optimierung möglich.

Auf einem Testzyklus um Stuttgart wird die prädiktive Energiemanagementstrategie, die durch das Boxen-Prinzip berechnet wird, mit einer im Versuchsfahrzeug vorhandenen heuristischen Strategie (Basisstrategie) verglichen. Ohne große Beeinflussung der Geschwindigkeit kann der Kraftstoffverbrauch um 10,9 % durch die prädiktive Strategie gesenkt werden. Die Effizienz der eingesetzten Energie wird gesteigert, während Schaltvorgänge und Motorstarts deutlich reduziert werden. Bei weiteren Untersuchungen wird das Potenzial der beiden Strategien bei unterschiedlichem Batterieladungszustand zu Beginn der Simulation sowie verschiedenen Streckenlängen bestimmt.

Die Fahrstrategie wird in einer weiteren Untersuchung parallel optimiert, indem ein Band (Fahrschlauch) um das Fahrprofil des Zyklus aufgespannt wird. Bei einer durchschnittlichen Abweichung der Geschwindigkeit um 1,15 % kann der Kraftstoffverbrauch im Vergleich zur Basisstrategie um 18 % gesenkt werden oder bei gleichem Verbrauch die Durchschnittsgeschwindigkeit um 21,1 % gesteigert werden. Der Einfluss der Breite des Fahrschlauchs auf den Komfort sowie die Wahl der Hybridmodi bei unterschiedlichen Gewichtungen der Kostenfunktion wird untersucht. Das Einsparpotenzial im Vergleich zur Basisstrategie ändert sich je nach Anfangsladezustand der Batterie und Streckenlänge und zeigt die Vorteile einer prädiktiven Strategie für die untersuchte Hybridkonfiguration. Ein Metamodell der Optimierung für diesen Fahrzyklus wird erstellt, das in einem Beispiel die Durchschnittsgeschwindigkeit mit 0,04 % Abweichung und den Verbrauch mit 2,69 % Abweichung vorbestimmen kann.

Eine serielle und parallele Optimierung der Fahrstrategie und der Energiemanagementstrategie wird für zwei Fahrsituationen und der gesamten Stuttgart-Runde verglichen. In einer kurzen Fahrsituation von 2 km wird das zusätzliche Potenzial der parallelen Optimierung gerade bei leerer Batterie deutlich. Auf einer längeren Strecke wie dem Stuttgart-Zyklus dominiert die Parametrierung der jeweiligen Berechnungsart, wodurch ein Vergleich nur exemplarisch erfolgen kann.

In weiteren Untersuchungen werden aktuelle Verkehrsdaten in der Simulation und auf einzelnen Messfahrten im Versuchsfahrzeug betrachtet. Die Leistung am Rad und an den Aggregaten wird mit und ohne Längsregelung prädiziert. Aktuelle Geschwindigkeiten von Datenlieferanten bilden ein real gefahrenes Geschwindigkeitsprofil sehr gut ab. Für eine Vorausplanung sind Verkehrsprädiktionsmodelle notwendig, die aus aufgezeichneten Geschwindigkeiten berechnet und von Datenlieferanten zur Verfügung gestellt werden. Diese werden für ausgewählte Fahrzyklen bewertet. Bei einem Vergleich der prädiktiven Strategie mit aktuellen Geschwindigkeitsinformationen und der Basisstrategie im Versuchsfahrzeug kann der Kraftstoffverbrauch im Schnitt um 3,97 % reduziert werden.

Auf weiteren Fahrzyklen wird der Einfluss der Güte der aktuellen Verkehrsinformationen auf die Optimierung untersucht und dafür eine gemessene Stausituation auf einer Autobahn-Runde verwendet. Die Einbindung aktueller Verkehrsinformationen reduziert den Kraftstoffverbrauch nur, wenn die Güte eines Verkehrsprädiktionsmodells hoch ist. Diese können uhrzeit- und tagesabhängige Spitzenlasten, wie den Berufsverkehr abbilden, sind jedoch meist konservativ abgeschätzt und können Stausituationen nur bedingt voraussagen. Von einer Verbesserung der Modelle und der damit verbundenen Prädiktionsgüte ist in naher Zukunft auszugehen.

Der Einfluss des Höhenprofils auf die optimale Energiemanagementstrategie wird auf einer Langstrecke von Ulm nach Bozen unter Verwendung aufgezeichneter Geschwindigkeiten untersucht. Auf längeren Strecken setzt sich die optimale Batterieladungsstrategie aus Entlade- und Ladephasen zusammen und weicht vom typischen Verlauf einer kontinuierlichen Entladestrategie ab. Diese Ergebnisse unterstreichen die Wichtigkeit einer Strategieplanung für Plug-in Hybridfahrzeuge bis zum Reiseziel. Das Höhenprofil korreliert dabei mit Lade- und Rekuperationsphasen und verdeutlicht das Rekuperationspotenzial auf Routen mit starkem Gefälle.

Die Auswirkungen der Reisezeiten auf verschiedenen Langstrecken wird untersucht und abschließend die Vorteile eines hybriden Antriebsstrangs einer konventionell angetriebenen Antriebsweise gegenübergestellt. Während der Verbrauch beim rein verbrennungsmotorischen Betrieb und langer Fahrzeit bzw. dichtem Verkehr in einer Untersuchung um 6,6 % zunimmt, fällt dieser im Vergleich zu einer hybriden Konfiguration um 3 % ab. Der Vorteil eines Plug-in Hybridfahrzeugs ist somit selbst auf Autobahnen gegeben, wenn durch die Verkehrssituation die Durchschnittsgeschwindigkeit so stark reduziert wird, dass die Vorteile einer E-Maschine mit besserem Wirkungsgrad zum Tragen kommen können.

In dieser Arbeit wird ein Fahrerassistenzsystem präsentiert, das einen Beitrag zu aktuellen Trends in der Autoindustrie liefert. Hybridfahrzeuge werden einen wachsenden Marktanteil haben und nicht nur im Premiumsegment vertreten sein. Die vollautomatisierte Längsregelung ist ein erster Schritt in Richtung autonomes Fahren. Eine Erweiterung der Fahrzeugführung durch eine Querregelung ist mit den erarbeiteten Methoden der mehrdimensionalen Optimierung durch eine Erweiterung der Modelle und Kostenfunktion möglich. Die Verwendung von aktuellen Verkehrsdaten über die Verbindung zu einem Backend zeigt, dass eine Vernetzung des Fahrzeugs greifbar nahe ist und welche Potenziale hier in Zukunft zu erwarten sind.

Durch die Anforderungen einer Echtzeitfähigkeit wurden verschiedene Methoden betrachtet, um eine Optimierung mit möglichst wenig Speicher und Rechenzeit auf einem Steuergerät zu realisieren. Die Skalierbarkeit der jeweiligen Methoden je nach Anforderung an Genauigkeit und Performance sowie der modulare Aufbau der Regelung beschleunigt eine Übertragung der erarbeiteten Methoden auf ein seriennahes Steuergerät. Weitere Untersuchungen mit jeweiliger Zielhardware in verschiedenen Versuchsfahrzeugen sind dafür notwendig.

Handlungsbedarf besteht in der Weiterentwicklung von Prädiktionsmodellen jeglicher Art: Der Fahrer wird bis zum vollständig autonomen Fahren immer wieder eingreifen müssen, wodurch eine Modellierung seines Verhaltens eine Anpassung ermöglicht, die die Akzeptanz des Systems fördern kann. Weitere Komponenten im Fahrzeug, wie z. B. das Thermomanagement des Motors oder die Klimaanlage können von der prädizierten Leistung profitieren sowie in die Optimierung integriert werden. Die Güte der Prädiktion des Verkehrs in Sichtweite und entlang der gesamten Fahrstrecke wird entscheidend für Kraftstoffeinsparungen sein, die im Fahrzeug erlangt werden können.

Für eine Absicherung des Fahrerassistenzsystems unter realen Verkehrsszenarien bietet sich die Verwendung von aufgezeichneten Verkehrsinformationen der Datenlieferanten aus der Navigation an. Ergänzend zu einzelnen Fahrscenarien ermöglichen sie, das Verkehrsverhalten in unterschiedlichen Ländern zu unterschiedlichen Uhrzeiten auf Basis aufgezeichneter aktueller Geschwindigkeiten zu simulieren und damit das System statistisch abzusichern. Die unbegrenzte Menge an Daten deckt einen Großteil an relevanten Szenarien ab. Sie ergänzen damit zeitaufwendige Messfahrten und stellen eine schnelle und frühzeitige Qualitätssicherung einzelner Funktionen bei Fahrerassistenzsystemen dar.

A. Anhang

A.1. Eingesetzte Versuchsfahrzeuge

	PORSCHE PANAMERA S HYBRID [43]	PORSCHE PANAMERA S E-HYBRID [44]
Konzept:	Paralleler Vollhybrid (FHEV)	Paralleler Plug-in Hybrid (PHEV)
Aggregate:		
Verbrennungsmotor	3,0-Liter V6	3,0-Liter V6
Max. Leistung	245 kW	245 kW
Max. Drehmoment	440 Nm	440 Nm
Elektromaschine	PSM	PSM
Max. Leistung	34 kW	70 kW
Max. Drehmoment	140 Nm	150 Nm
Gesamt		
Max. Leistung	279 kW	306 kW
Max. Drehmoment	580 Nm	590 Nm
HV-Batterie:		
Zellmaterial	Nickel-Metallhydrid	Lithium-Ionen
Kapazität	1,8 kWh	9,4 kWh
Konfiguration:		
Motorlage	Frontmotor	Frontmotor
Antrieb	Heckantrieb	Heckantrieb
Getriebe	8-Gang Tiptronic S	8-Gang Tiptronic S
Fahrleistung:		
E-Reichweite (NEFZ)	3 km	36 km
el. Höchstgeschwindigkeit	bis 75 km/h	135 km/h
Höchstgeschwindigkeit	270 km/h	270 km/h
Beschleunigung 0-100 km/h	6,0s	5,5s
Verbrauch (NEFZ):		
Innerorts	7,6 l/100km	-
Außerorts	6,8 l/100km	-
Kombiniert	7,1 l/100km	3,1 l/100km
CO ₂ -Emissionen	167 g/km	71 g/km

A.2. Validierung des Fahrzeugmodells

Tab. A.1.: Eingangs- und Ausgangssignale der betrachteten MISO Systeme zur Validierung der Fahrzeugmodell-Funktionen sortiert nach Frequenz f der zugehörigen CAN-Botschaften und betrachteten Testfällen nach [180].

Nr.	f [Hz]	Eingangssignale	f [Hz]	Ausgangssignal
1	100	Elektrisches Moment T_{EM}	50	Geschwindigkeit v_x
	100	Verbrennermoment T_{ICE}		
	100	Lenkradwinkel α_{swa}		
	50	Geschwindigkeit v_x		
	50	Gang z		
	50	Zustand der Kupplung b_{CE}		
	10	Steigung α_s		
2	50	Geschwindigkeit v_x	100	Motordrehzahl ω_4
	50	Gang z		
	50	Radgeschwindigkeiten v_w		
3	100	Elektrisches Moment T_{EM}	10	Batterieladezustand SoC
	100	Motordrehzahl ω_4		
	100	Hochvolt-Spannung U_{HV}		
	100	Hochvolt-Strom I_{HV}		
	2	Strom PTC-Heizung I_{PTC}		
	2	Strom Klimakompressor I_{AC}		
4	-	Abtastzeit t_s	100	Batteriestrom I_{Bat}
	100	Elektrisches Moment T_{EM}		
	100	Motordrehzahl ω_4		
	100	Hochvolt-Spannung U_{HV}		
	100	Hochvolt-Strom I_{HV}		
	10	Batterieladezustand SoC		
	2	Strom PTC-Heizung I_{PTC}		
	2	Strom Klimakompressor I_{AC}		
5	100	Motordrehzahl ω_4	100	Elektrisches Moment T_{EM}
	100	Hochvolt-Spannung U_{HV}		
	100	Hochvolt-Strom I_{HV}		
	10	Batterieladezustand SoC		
	2	Strom PTC-Heizung I_{PTC}		
	2	Strom Klimakompressor I_{AC}		
	-	Abtastzeit t_s		

A.3. Fahrzyklen

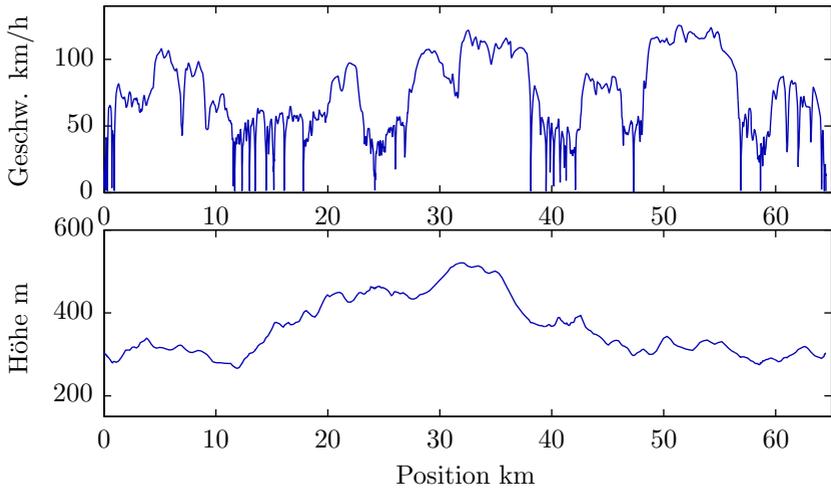


Abb. A.1.: Streckeninformationen der Stuttgart-Runde

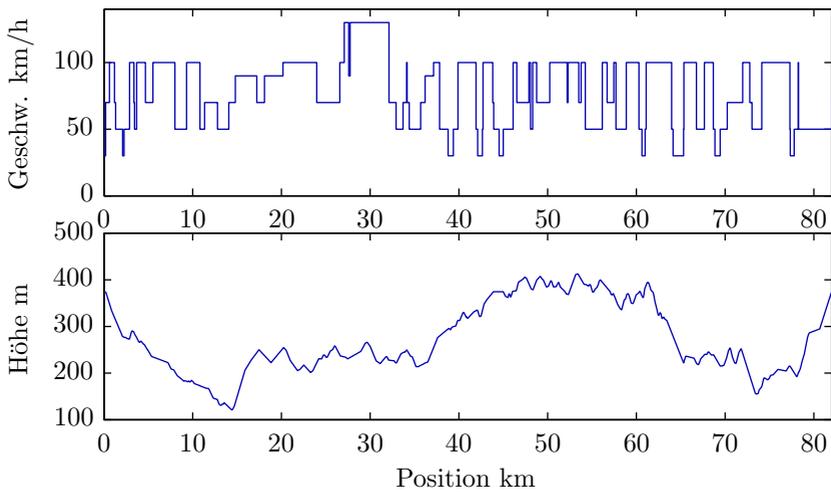


Abb. A.2.: Streckeninformationen der Deutschland-Runde

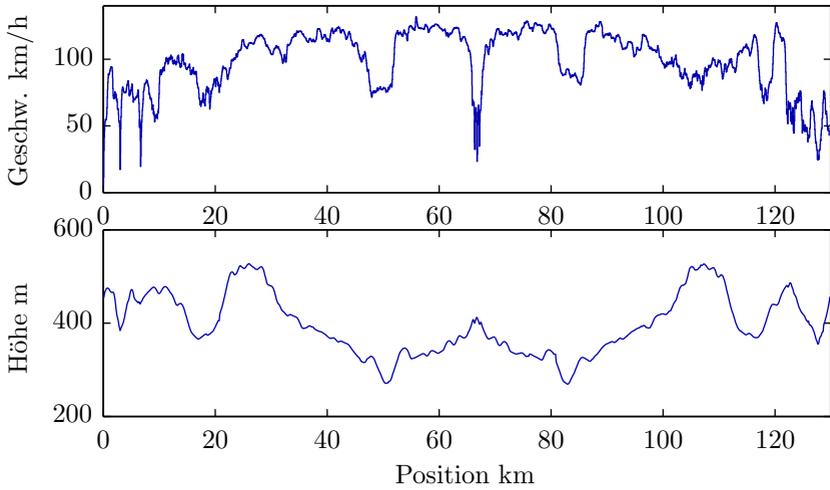


Abb. A.3.: Streckeninformationen der Autobahn-Runde

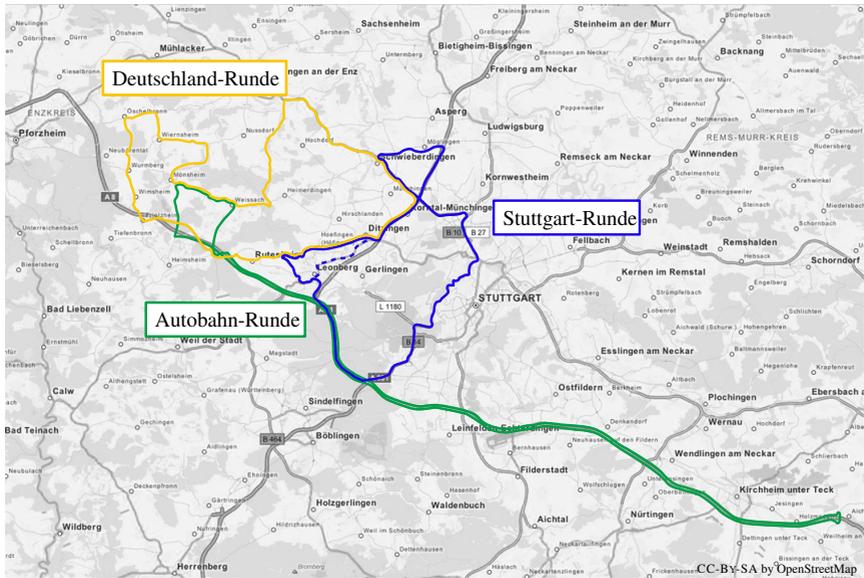


Abb. A.4.: Betrachtete Fahrzyklen im Großraum Stuttgart

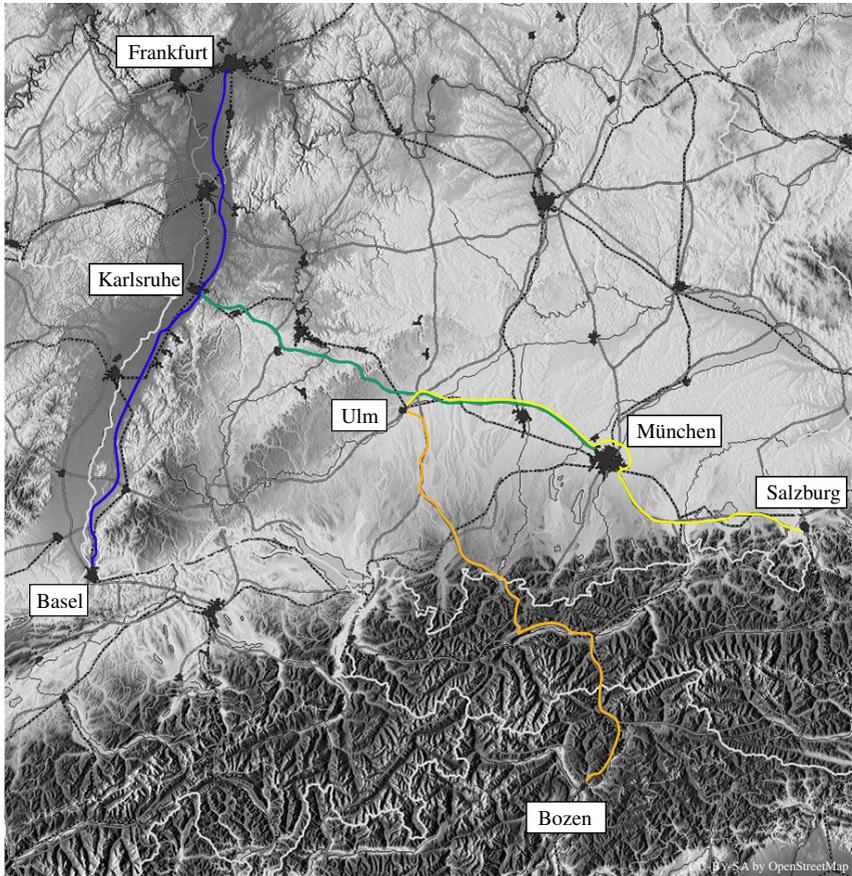


Abb. A.5.: Langstrecken-Routen in Mitteleuropa

A.4. Metamodellierung der Simulation

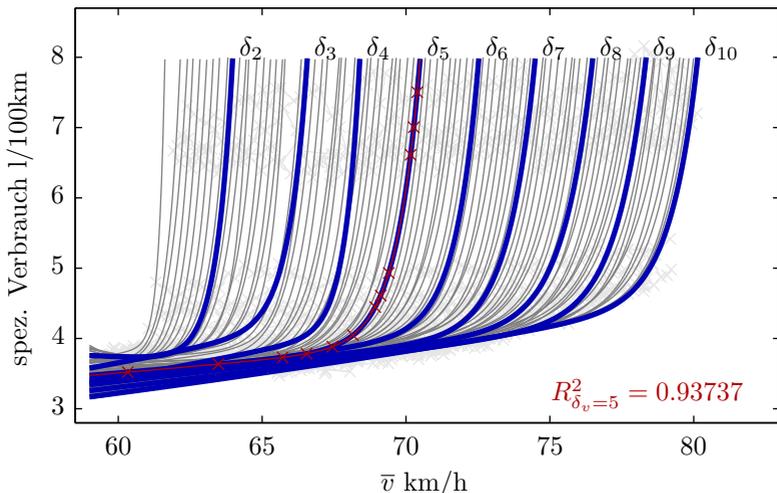


Abb. A.6.: Funktionale Beschreibung des Einflusses der Fahrschlauchbreite auf den spez. Verbrauch über der Durchschnittsgeschwindigkeit

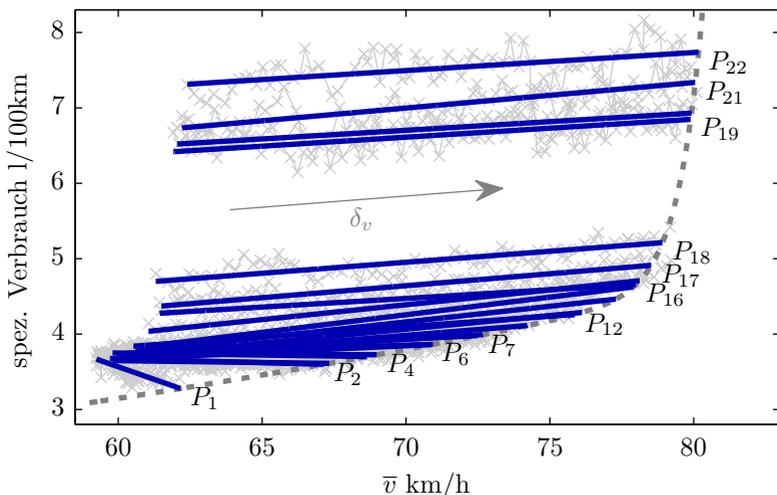


Abb. A.7.: Funktionale Beschreibung des Einflusses der Fahrschlauchbreite bei unterschiedlich gewichteten Kostenfunktionen

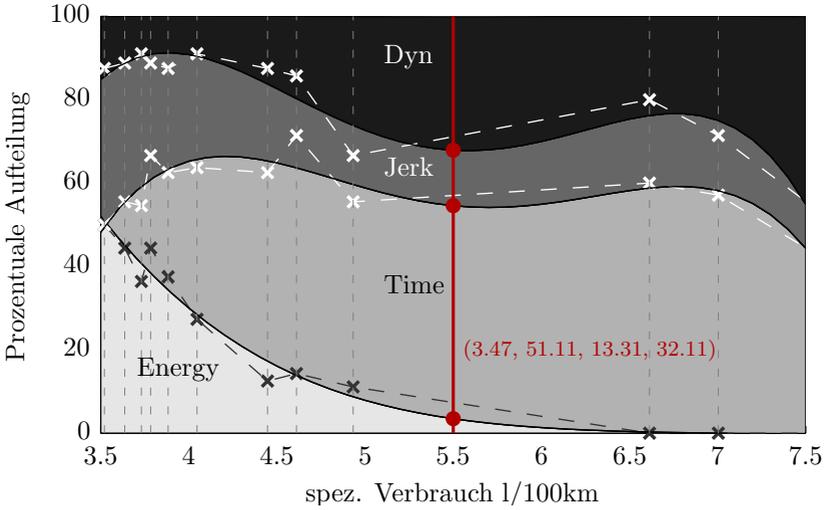


Abb. A.8.: Parameter der Kostenfunktion über dem spezifischen Verbrauch für die Fahrschlauchbreite $\delta_s = 5 \text{ m/s}$

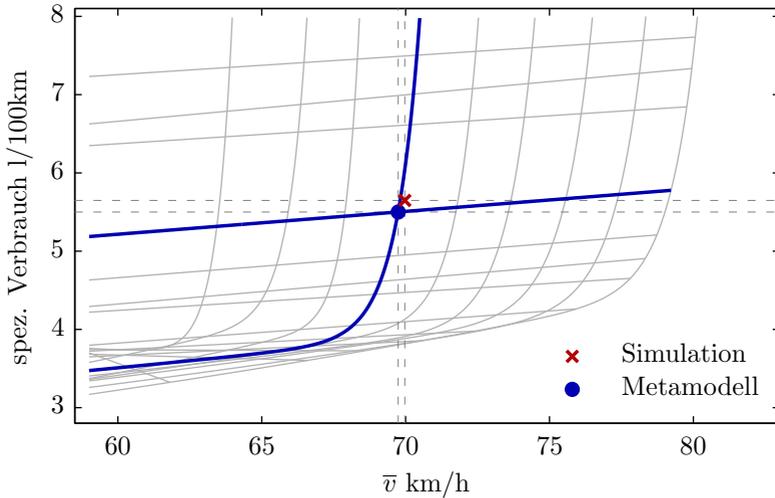


Abb. A.9.: Funktionale Beschreibung des Einflusses der Fahrschlauchbreite auf den spez. Verbrauch über der Durchschnittsgeschwindigkeit

A.5. Leistungsprädiktion in Längsregelung

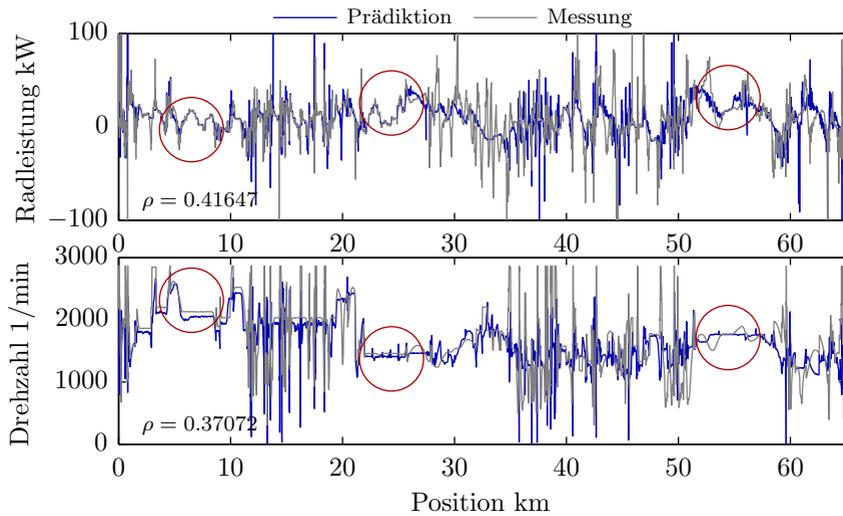


Abb. A.10.: Prädizierte und gemessene Radleistung und Getriebeeingangsdrehzahl auf der Stuttgarterunde in Längsregelung

A.6. Langstreckenanalyse

A.6.1. Höhenprofil

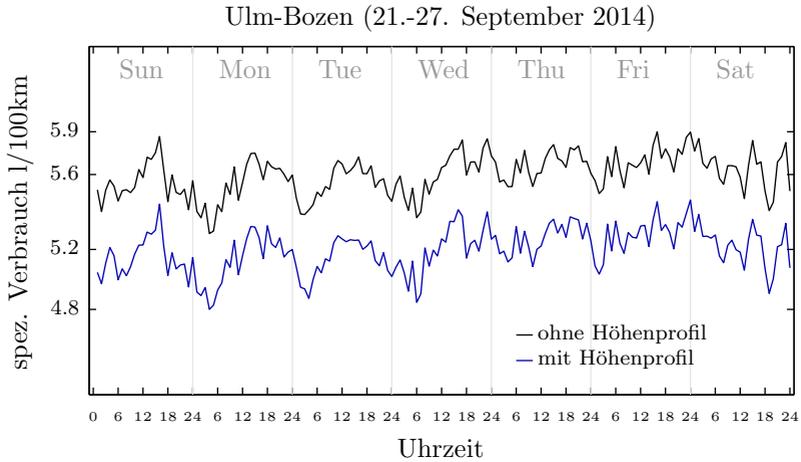


Abb. A.11.: Verbrauch je Uhrzeit und Wochentag

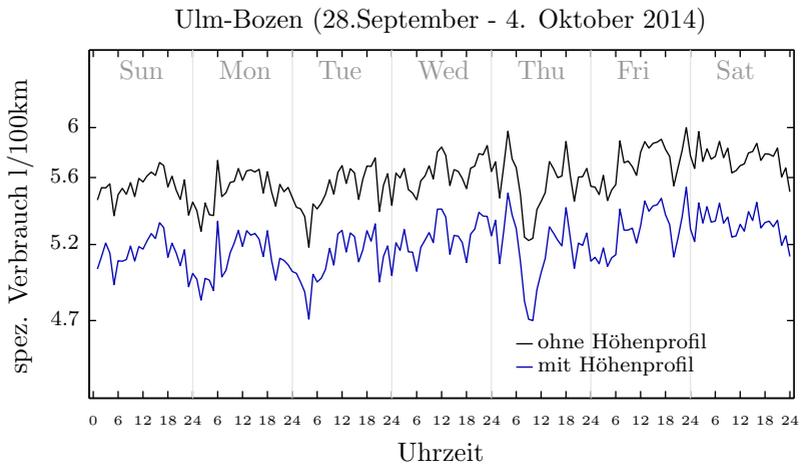


Abb. A.12.: Verbrauch je Uhrzeit und Wochentag

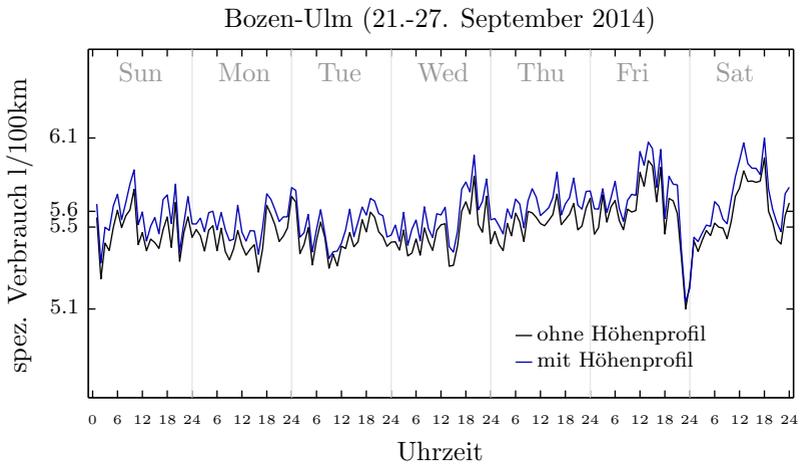


Abb. A.13.: Verbrauch je Uhrzeit und Wochentag

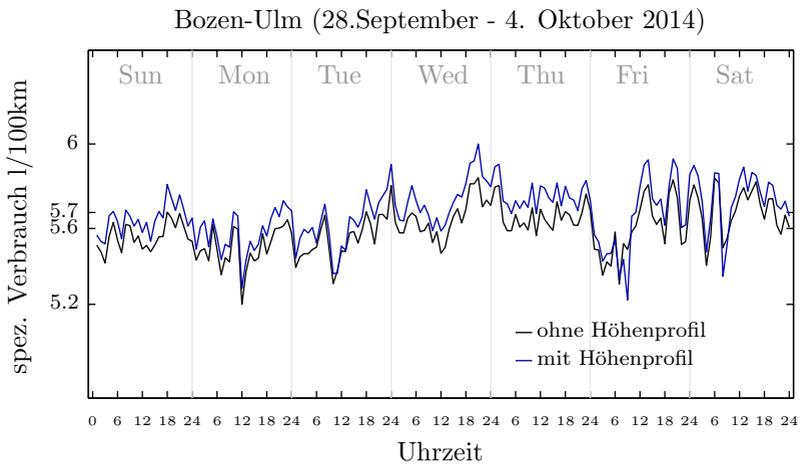


Abb. A.14.: Verbrauch je Uhrzeit und Wochentag

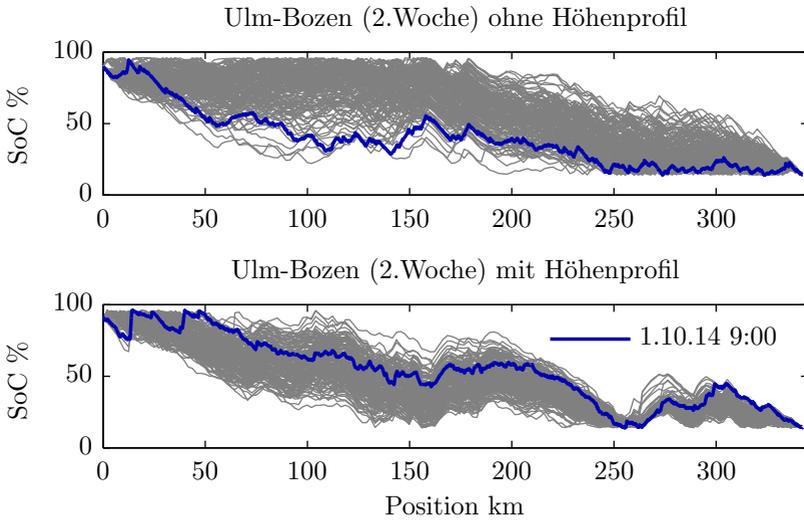


Abb. A.15.: LongRange-Strategie auf der Langstrecke Ulm-Bozen

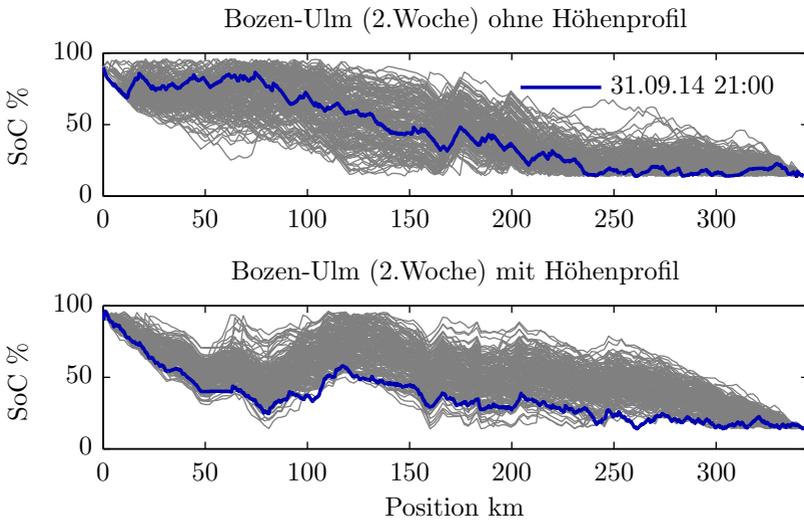


Abb. A.16.: LongRange-Strategie auf der Langstrecke Bozen-Ulm

A.6.2. Reisezeit

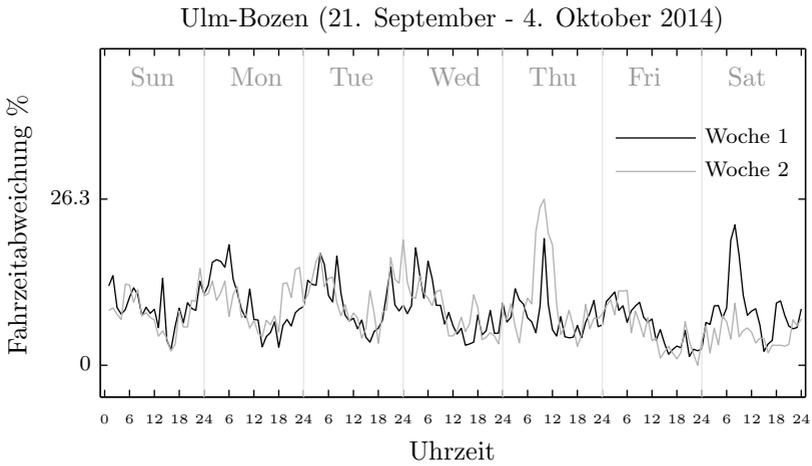


Abb. A.17.: Reisezeiten auf der Langstrecke Ulm-Bozen

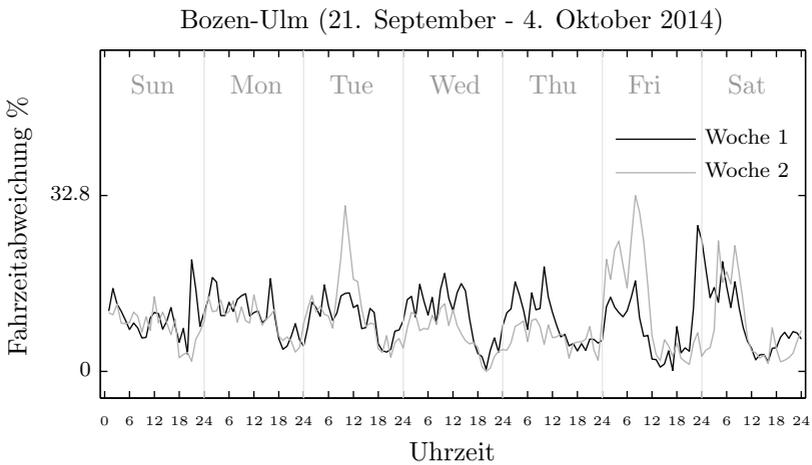


Abb. A.18.: Reisezeiten auf der Langstrecke Bozen-Ulm

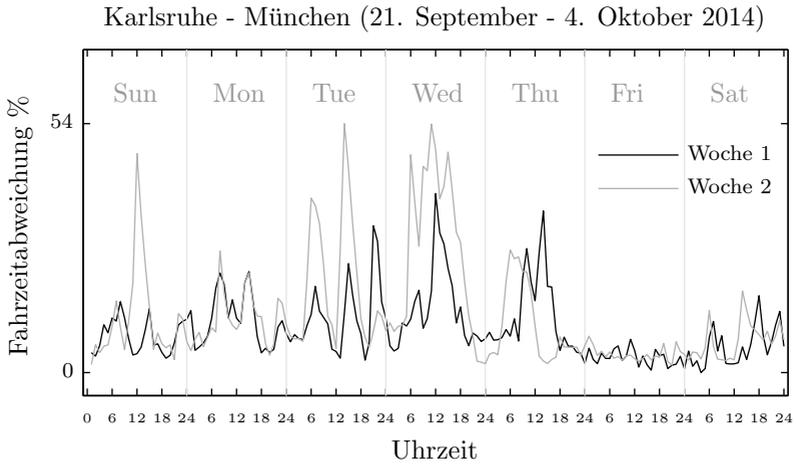


Abb. A.19.: Reisezeiten auf der Langstrecke Karlsruhe-München

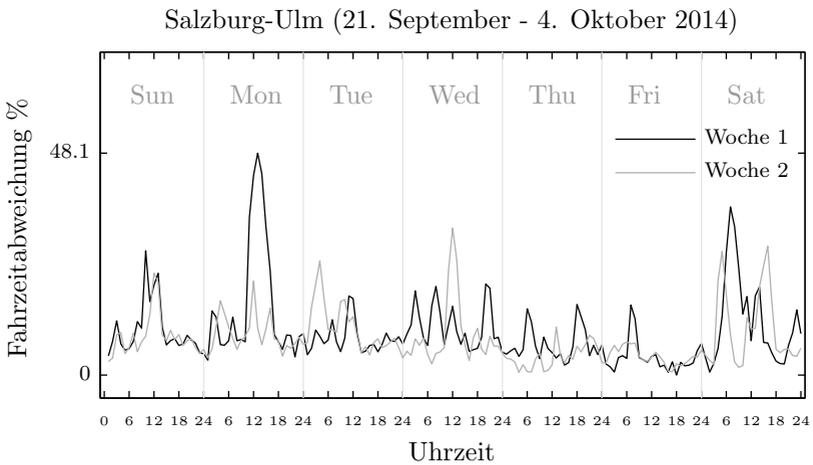


Abb. A.20.: Reisezeiten auf der Langstrecke Salzburg-Ulm

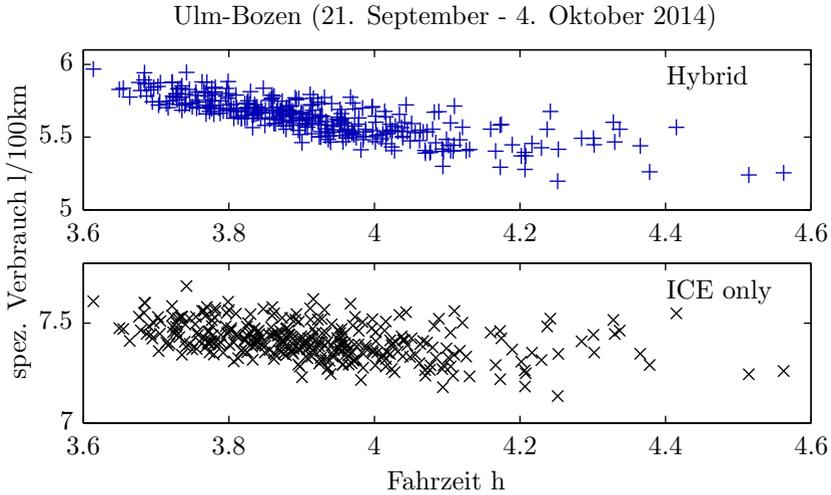


Abb. A.21.: Vergleich der Verbrauchswerte für eine hybride Energiemanagementstrategie (Hybrid) und einer rein verbrennungsmotorischen Fahrt (ICE only) auf der Langstrecke Ulm-Bozen

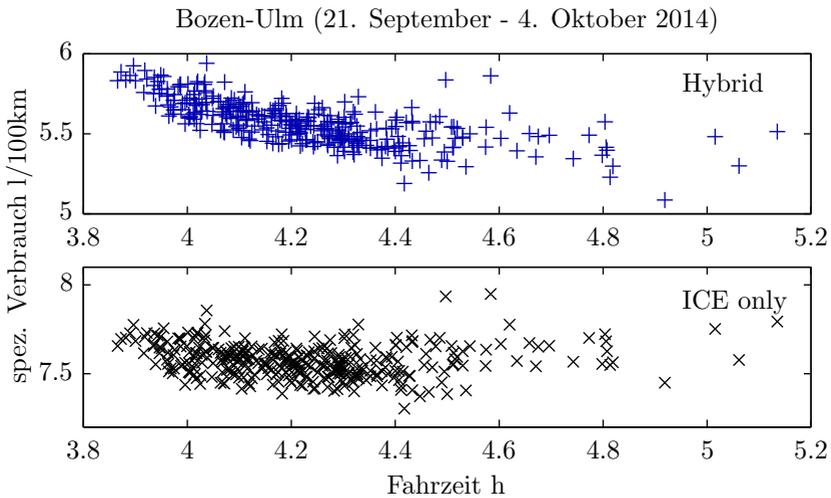


Abb. A.22.: Vergleich der Verbrauchswerte für eine hybride Energiemanagementstrategie (Hybrid) und einer rein verbrennungsmotorischen Fahrt (ICE only) auf der Langstrecke Bozen-Ulm

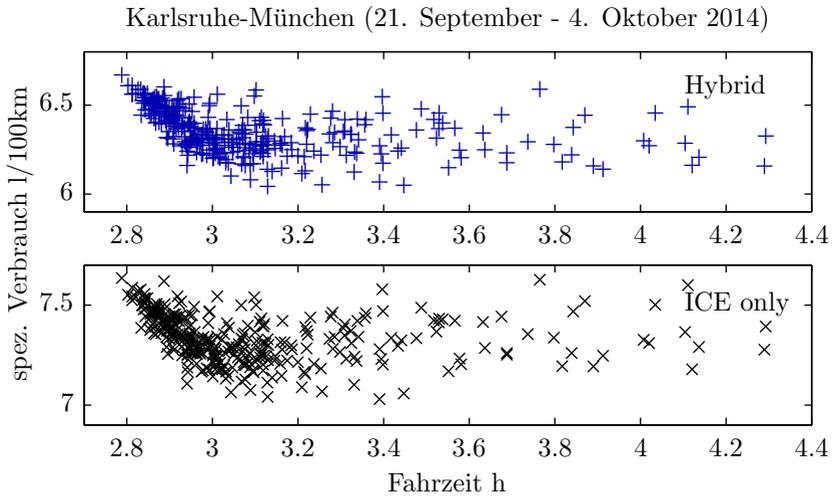


Abb. A.23.: Vergleich der Verbrauchswerte für eine hybride Energiemanagementstrategie (Hybrid) und einer rein verbrennungsmotorischen Fahrt (ICE only) auf der Langstrecke Karlsruhe-München

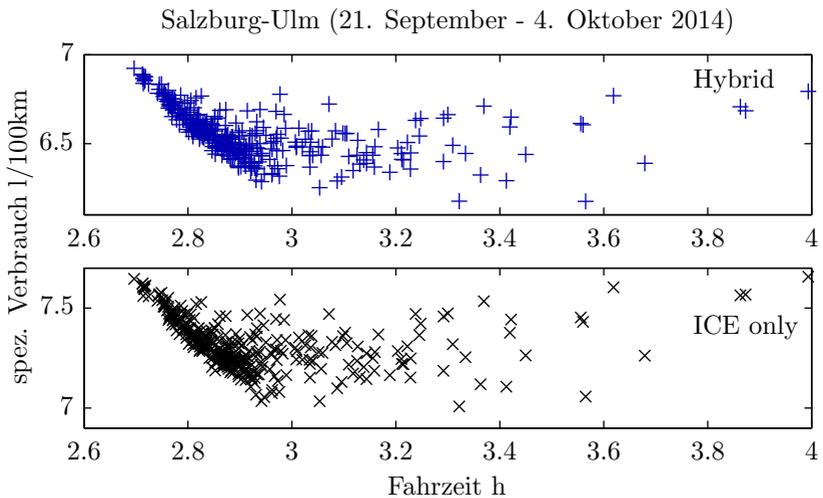


Abb. A.24.: Vergleich der Verbrauchswerte für eine hybride Energiemanagementstrategie (Hybrid) und einer rein verbrennungsmotorischen Fahrt (ICE only) auf der Langstrecke Salzburg-Ulm

A.7. Optimale Regelung einer Batteriezustandsplanung

Mit der Dynamischen Programmierung kann eine optimale Regelstrategie gefunden werden, die durch die Riccati-Gleichung als optimale Regelung bewiesen werden kann. Als Beispiel dient die Suche nach der optimalen Momentenaufteilung und der damit verbundenen Batterie-ladezustandsplanung. Die Lösung des Variationsproblems wird im Folgenden in Anlehnung an [56] und [152] beschrieben:

Nach [57] ist das dynamische System durch folgende Zustandsdifferenzgleichung gegeben:

$$\underline{x}_{k+1} = \underline{x}_k + \underline{B}_k \underline{u}_k, \quad \text{für } k = 0, 1, 2, \dots, N \quad (\text{A.1})$$

Es wird vorausgesetzt, dass das System vollständig steuerbar und beobachtbar ist. Der Zustandsvektor \underline{x}_k repräsentiert den Batterie-ladezustand (SoC). \underline{B}_k ist eine (n,p) -Matrix, die stabil ist und vom Höchststrang $p \leq n$ vorausgesetzt werden darf. \underline{B}_k repräsentiert das Fahrzeugmodell, das in jedem Schritt k für eine geforderte Leistung das Gesamtdrehmoment darstellt. Durch einzelne Komponenten wie z. B. der Wirkungsgrad der Batterie hängt \underline{B}_k vom Zustand ab. Da von einer gewissen Trägheit des Systems ausgegangen werden kann, ist eine Linearisierung um einen stationären Zustand bei einer geeigneten Wahl der Diskretisierung des Zustandsvektors möglich [57]. \underline{B}_k ist damit unabhängig von \underline{x} für kleine Δk und kleine $\Delta x = x(i+1) - x(i)$.

Der Steuervektor \underline{u}_k repräsentiert die Aufteilung des Gesamtdrehmoments in ein verbrennungsmotorisches Drehmoment T_{ICE} und ein elektrisches Drehmoment T_{EM} .

$$\underline{x}_k = \underline{s}, \quad \underline{u}_k = \begin{bmatrix} T_{\text{ICE}} \\ \sqrt{T_{\text{ICE}}} \\ 1 \\ T_{\text{EM}} \end{bmatrix} \quad (\text{A.2})$$

Die Belegung mehrerer Komponenten von T_{ICE} in \underline{u}_k vereinfacht die Rechnung mit einem quadratischen Gütemaß.

Als Gütemaß wird der kumulierte Kraftstoffverbrauch allein betrachtet:

$$J = \int_0^{t_e} (\dot{m}_f(\omega, T_{\text{ICE}})) \, dt \quad (\text{A.3})$$

Eine analytische Approximation des meist in Kennfeldern verzeichneten Kraftstoffverbrauchs kann durch folgendes Polynomialmodell beschrieben werden [147]:

$$\dot{m}_f(\omega, T_{\text{ICE}}) = (\alpha_1 + \alpha_2 \omega^2) \cdot (\beta_0 + \beta_1 T_{\text{ICE}} + \beta_2 T_{\text{ICE}}^2) \quad (\text{A.4})$$

Das Gütefunktional zur Gewichtung der Bewegung des Systems wird wie folgt diskret beschrieben:

$$J(\underline{x}, \underline{u}) = \underline{x}_N^\top Q_N \underline{x}_N + \sum_{k=0}^{N-1} \left(\underline{u}_k^\top \underline{R} \underline{u}_k \right) \quad (\text{A.5})$$

Der Kraftstoffverbrauch spiegelt sich in den Schrittkosten $\underline{u}_k^\top \underline{R} \underline{u}_k$ wider, während der gewünschte Batterieladezustand in $k = N$ durch \underline{Q}_N beeinflusst werden kann. \underline{R} ist positiv definit für $\alpha_1, \alpha_2, \beta_0, \beta_1, \beta_2 > 0$:

$$\underline{R} = \begin{bmatrix} \beta_2(\alpha_1 + \alpha_2 \omega^2) & 0 & 0 & 0 \\ 0 & \beta_1(\alpha_1 + \alpha_2 \omega^2) & 0 & 0 \\ 0 & 0 & \beta_0(\alpha_1 + \alpha_2 \omega^2) & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix} \quad (\text{A.6})$$

Formel A.5 kann nach der BELLMANSchen Rekursionsgleichung wie folgt geschrieben werden:

$$J_k(\underline{x}_k, \underline{u}_k) = \min_{\underline{u}_k} \left\{ \underbrace{\underline{u}_k^\top \underline{R} \underline{u}_k + J_{k+1}(\underline{x}_{k+1}, \underline{u}_{k+1})}_{M(\underline{x}_k, \underline{u}_k)} \right\}$$

für $k = 0, 1, \dots, N-1$ (A.7)

Es wird angenommen, dass der optimale Regler \underline{K} linear vom Zustand abhängt. Da die aufkumulierten Schrittkosten für jeden Zustand in k abgespeichert werden, kann auch davon ausgegangen werden, dass das Gütemaß $J_k = J_k(\underline{x}_k, \underline{u}_k)$ quadratisch vom Zustand \underline{x}_k abhängt.

$$\underline{u}_k = -\underline{K}_k \underline{x}_k, \quad J_k = \underline{x}_k^\top \underline{Q}_k \underline{x}_k. \quad (\text{A.8})$$

Der zu minimierende Term $M(\underline{x}_k, \underline{u}_k)$ ist damit:

$$M(\underline{x}_k, \underline{u}_k) = \underline{u}_k^\top \underline{R} \underline{u}_k + \underline{x}_{k+1}^\top \underline{Q}_{k+1} \underline{x}_{k+1}$$

Wird die Systemgleichung (A.1) eingesetzt, folgt

$$\begin{aligned} &= \underline{u}_k^\top \underline{R} \underline{u}_k + (\underline{x}_k + \underline{B}_k \underline{u}_k)^\top \underline{Q}_{k+1} (\underline{x}_k + \underline{B}_k \underline{u}_k) \\ &= \underline{u}_k^\top \underline{R} \underline{u}_k + \underline{x}_k^\top \underline{Q}_{k+1} \underline{x}_k + \underbrace{(\underline{B}_k \underline{u}_k)^\top \underline{Q}_{k+1} \underline{x}_k + \underline{x}_k^\top \underline{Q}_{k+1} (\underline{B}_k \underline{u}_k) + (\underline{B}_k \underline{u}_k)^\top \underline{Q}_{k+1} (\underline{B}_k \underline{u}_k)}_{*} \end{aligned}$$

* da \underline{Q}_{k+1} symmetrisch: $((\underline{B}_k \underline{u}_k)^\top \underline{Q}_{k+1} \underline{x}_k)^\top = \underline{x}_k^\top \underline{Q}_{k+1} (\underline{B}_k \underline{u}_k)$

$$= \underline{u}_k^\top (\underline{R} + \underline{B}_k^\top \underline{Q}_{k+1} \underline{B}_k) \underline{u}_k + 2((\underline{B}_k \underline{u}_k)^\top \underline{Q}_{k+1} \underline{x}_k) + \underline{x}_k^\top \underline{Q}_{k+1} \underline{x}_k \quad (\text{A.9})$$

Als notwendige Bedingung wird die partielle Ableitung nach \underline{u}_k gebildet:

$$\frac{dM}{d\underline{u}_k} = 2(\underline{R} + \underline{B}_k^\top \underline{Q}_{k+1} \underline{B}_k) \underline{u}_k + 2\underline{B}_k^\top \underline{Q}_{k+1} \underline{x}_k \quad (\text{A.10})$$

Nach Null gesetzt folgt das optimale Regelungsgesetz für $k = 0, 1, \dots, N-1$:

$$\underline{u}_k^* = -(\underline{R} + \underline{B}_k^\top \underline{Q}_{k+1} \underline{B}_k)^{-1} \underline{B}_k^\top \underline{Q}_{k+1} \underline{x}_k \quad (\text{A.11})$$

Die zweite Ableitung nach \underline{u}_k ist:

$$\frac{d^2 M}{d\underline{u}_k^2} = 2(\underline{R} + \underline{B}_k^\top \underline{Q}_{k+1} \underline{B}_k) \quad (\text{A.12})$$

Nach [56] kann gezeigt werden, dass M positiv definit ist und damit ein eindeutiges Minimum besitzt. Die inverse Matrix in A.11 existiert, da \underline{R} als positiv definit vorausgesetzt wurde und zu ihr nur noch eine nicht negativ definite Matrix hinzuaddiert wird [152]. Setzt man $M(\underline{u}_k^*)$ in A.7 ein so erhält man mit A.8 und $\underline{u}_k^{*\top} = -\underline{x}_k^\top \underline{Q}_{k+1} \underline{B}_k (\underline{R} + \underline{B}_k^\top \underline{Q}_{k+1} \underline{B}_k)^{-1}$:

$$\begin{aligned} \underline{x}_k^\top \underline{Q}_k \underline{x}_k &= \min_{\underline{u}_k} M(\underline{u}_k) = M(\underline{u}_k^*) \\ &= \underline{x}_k^\top \underline{Q}_{k+1} \underline{B}_k (\underline{R} + \underline{B}_k^\top \underline{Q}_{k+1} \underline{B}_k)^{-1} (\underline{R} + \underline{B}_k^\top \underline{Q}_{k+1} \underline{B}_k) \\ &\quad \cdot (\underline{R} + \underline{B}_k^\top \underline{Q}_{k+1} \underline{B}_k)^{-1} \underline{B}_k^\top \underline{Q}_{k+1} \underline{x}_k \\ &\quad - 2 \underline{x}_k^\top \underline{Q}_{k+1} \underline{B}_k (\underline{R} + \underline{B}_k^\top \underline{Q}_{k+1} \underline{B}_k)^{-1} \underline{Q}_{k+1} \underline{B}_k^\top \underline{x}_k \\ &\quad + \underline{x}_k^\top \underline{Q}_{k+1} \underline{x}_k \end{aligned} \quad (\text{A.13})$$

Nach einem Koeffizientenvergleich folgt:

$$\begin{aligned} \underline{Q}_k &= \underline{Q}_{k+1} \underline{B}_k (\underline{R} + \underline{B}_k^\top \underline{B}_k)^{-1} \underline{B}_k^\top \underline{Q}_{k+1} + \underline{Q}_{k+1} \\ &\quad k = N-1, N-2, \dots, 0. \end{aligned} \quad (\text{A.14})$$

\underline{Q}_k wird rekursiv bestimmt, wobei $\underline{Q}_N = 0$ für \underline{x}_N den letzten Zustand im Entscheidungsprozess darstellt.

Im Fall $N \rightarrow \infty$ gilt $\underline{Q}_{k+1} = \underline{Q}_k = \underline{Q}$, sodass aus A.14 folgt:

$$\underline{Q} = \underline{Q} \underline{B}_k (\underline{R} + \underline{B}_k^\top \underline{Q} \underline{B}_k)^{-1} \underline{B}_k^\top \underline{Q} + \underline{Q} \quad (\text{A.15})$$

Das optimale Regelungsgesetz für einen konstanten Regler lautet dann:

$$\begin{aligned} \underline{u}_k^* &= -(\underline{R} + \underline{B}_k^\top \underline{Q} \underline{B}_k)^{-1} \underline{B}_k^\top \underline{Q} \underline{x}_k \\ k &= 0, 1, \dots \end{aligned} \quad (\text{A.16})$$

A.15 entspricht der algebraischen Riccati-Gleichung und kann auch numerisch gelöst werden, indem z. B. \underline{Q} iterativ angenähert wird bis $|\underline{Q}_{k+1} - \underline{Q}_k| < \varepsilon$ (KLEINMAN und SMITH [56]). Ein weitere Lösung der Riccati-Gleichung ist in [111] zu finden.

B. Abkürzungen, Schreibweisen und Formelzeichen

Abkürzungen

AC	Air Conditioner
ACC	Adaptive Cruise Control
ADAS	Advanced Driver Assistance System
ADP	Adaptive Dynamische Programmierung
ADTF	Automotive Data and Time-Triggered Framework
AER	All Electric Range
API	Application Programming Interface
C2C	Car-to-Car
C2I	Car-to-Infrastructure
CAN	Controller Area Network
CD	Charge Depleting
CDP	Continuous Dynamic Programming
CFPD	Cellular Floating Phone Data
CI	Charge Increasing
CS	Charge Sustaining
DDP	Diskrete Dynamische Programmierung
DP	Dynamische Programmierung
DoE	Design of Experiments
ECMS	Equivalent Consumption Minimization Strategy
ECU	Electronic Control Unit
EKI	Energiekostenindikator
EM	Electric Machine
ESP	Elektronisches Stabilisierungsprogramm
EH	Electronic Horizon
EHP	Electronic Horizon Provider
EHR	Electronic Horizon Reconstructor
FCD	Floating Car Data
FHEV	Full Hybrid Electric Vehicle
GPRS	General Packet Radio Service
GPS	Global Positioning System

GUI	Graphical User Interface
HEV	Hybrid Electric Vehicle
HMI	Human Machine Interface
HTTP	Hypertext Transfer Protocol
HV	High Voltage
ICE	Internal Combustion Engine
IDP	Iterative Dynamische Programmierung
IPPC	Integrated Predictive Powertrain Control
LKW	Lastkraftwagen
LPV	Lastpunktverschiebung
MHEV	Mild Hybrid Electric Vehicle
MISO	Multiple Input Single Output
MPC	Model Predictive Control
MPP	Most Probable Path
NEFZ	Neuer Europäischer Fahrzyklus
NMPC	Nonlinear Model Predictive Control
OSMPC	One-Step Model Predictive Control
PEMS	Portable Emission Measurement System
PHEV	Plug-In Hybrid Electric Vehicle
PSM	Permanenterregten Synchronmaschine
PTC	Positive Temperature Coefficient
RCG	Random Cycle Generator
RDE	Real Drive Emissions
RDS	Radio Data System
SBAS	Satellitenbasiertes Ergänzungssystem
SoC	State of Charge
TA	Timing Advance
TFD	Traffic Flow Data
TMC	Traffic Message Channel
UMTS	Universal Mobile Telecommunications System
UNECE	United Nations Economic Commission for Europe
WLTC	Worldwide Harmonized Light Vehicle Test Cycle

Schreibweisen

Notation	Bedeutung
x	Skalar
\underline{x}	Vektor
\mathcal{X}	Menge
$f(\cdot)$	Funktion f von (\cdot)
$\min(\cdot)$	Minimum von (\cdot)
$\arg \min(\cdot)$	Argument, welches (\cdot) minimiert
$(\cdot)_k$	Wert von (\cdot) in Stufe k des Entscheidungsprozesses
$(\cdot)^*$	optimale Ausprägung von (\cdot)
$(\dot{\cdot})$	zeitliche Änderung von (\cdot)
$ (\cdot) $	Betrag von (\cdot)
$(\bar{\cdot})$	Durchschnitt von (\cdot)
$(\cdot)^{-1}$	Inverse von (\cdot)
$(\cdot)^\top$	Transponierte von (\cdot)
$(\cdot)^{M \times N}$	Matrixschreibweise von (\cdot) mit der Dimension M und N
$x \in [a, b]$	x ist Element einer geschlossenen Menge, $a \leq x \leq b$
$x \in \mathcal{X}$	x ist Element einer geschlossenen Menge, \mathcal{X}
$\forall x \in \mathcal{X}$	für alle x einer geschlossenen Menge, \mathcal{X}

Indizes

Notation	Bedeutung
$(\cdot)_{\text{abs}}$	absoluter Wert
$(\cdot)_{\text{calc}}$	berechneter Wert
$(\cdot)_{\text{ges}}$	Gesamtwert
$(\cdot)_{\text{ist}}$	Istwert
$(\cdot)_{\text{max}}$	Maximalwert
$(\cdot)_{\text{meas}}$	gemessener Wert
$(\cdot)_{\text{min}}$	Minimalwert
$(\cdot)_{\text{model}}$	Modellierte Größe
$(\cdot)_{\text{pred}}$	prädictierter Wert
$(\cdot)_{\text{rel}}$	relativer Wert
$(\cdot)_{\text{sens}}$	Messwert eines Sensors
$(\cdot)_{\text{soll}}$	Sollwert

Formelzeichen und Symbole

Fahrzeugmodell

Zeichen	Bedeutung	Einheit
a_x	Längsbeschleunigung	m/s^2
A_L	projizierte Fahrzeugfläche	m^2
c	binärer Zustand der Trennkupplung	-
$C_{\text{lat},h}$	Schräglaufsteifigkeit Hinterachse (Einspurmodell)	N/rad
$C_{\text{lat},v}$	Schräglaufsteifigkeit Vorderachse (Einspurmodell)	N/rad
$e_{z,c}$	Massenfaktor	-
E_{chem}	chemische Energie für einen Wiederstartvorgang	J
E_{chem}	elektrische Energie für einen Wiederstartvorgang	J
E_{ges}	Gesamtenergie	J
f_R	Rollwiderstandsbeiwert	-
F_a	Beschleunigungswiderstand	N
$F_{a,\text{rot}}$	Beschleunigungswiderstand (rotatorisch)	N
$F_{a,\text{trans}}$	Beschleunigungswiderstand (translatorisch)	N
F_L	Luftwiderstand	N
F_N	Gesamtgewichtskraft	N
F_R	Radwiderstand	N
$F_{R,K}$	Kurvenwiderstand	N
$F_{R,L}$	Lagerreibung	N
$F_{R,R}$	Rollwiderstand	N
$F_{R,V}$	Vorspurwiderstand	N
F_{St}	Steigungswiderstand	N
F_x	Gesamtwiderstand in Längsrichtung	N
$F_{y,h}$	Seitenkraft Hinterachse	N
$F_{y,v}$	Seitenkraft Vorderachse	N
F_Z	Zentrifugalkraft	N
g	Fallbeschleunigung	m/s^2
H	Hybridisierungsgrad	%
H_u	untere Heizwert des Kraftstoffs	kJ / kg
i_D	Übersetzungsverhältnis Differential	-
$i_G(z)$	Übersetzungsverhältnisje Gang z	-
$J_{(\cdot)}$	Trägheit von (\cdot)	$\text{kg} \cdot \text{m}^2$
I_{Bat}	Strom der HV-Batterie	A
l	Radstand	m
l_h	Abstand Schwerpunkt Hinterachse	m
l_v	Abstand Schwerpunkt Vorderachse	m
m	Fahrzeugmasse	kg

\dot{m}_f	gravimetrische Stundenverbrauch	kg/h
m_f	absoluter Kraftstoffverbrauch	l
$m_{f,\text{korr}}$	absoluter Kraftstoffverbrauch (korrigiert)	l
p	Straßensteigung	%
p_∞	Staudruck	N/m ²
P_{aus}	Ausschaltleistung des ICE	kW
P_{ein}	Einschaltleistung des ICE	kW
P_{AC}	Leistung der Klimaanlage	kW
P_{Bat}	Leistung der HV-Batterie	kW
P_{chem}	chemische Leistung	kW
P_{EM}	Leistung der E-Maschine	kW
$P_{\text{EM,loss}}$	Verlustleistung der E-Maschine	kW
P_{el}	elektrische Leistung	kW
P_{ges}	Gesamtleistung	kW
P_{grid}	elektrische Leistung aus dem Stromnetz	kW
P_{ICE}	Leistung des Verbrennungsmotors	kW
P_{ob}	Bordnetzleistung	kW
P_{PTC}	Leistung der Heizung	kW
P_R	Radleistung	kW
q	Momentenaufteilung	-
r_{dyn}	dynamischer Radhalbmesser	m
r_L	Lagerhalbmesser	m
r_{Bat}	Residuum gemessenen zur berechneten Batterieströme	A
r_{EM}	Residuum gemessenen zur berechneten Momente (EM)	Nm
R_i	Innenwiderstand der HV-Batterie	Ω
SoC	Batterieladezustand der HV-Batterie	%
t_{wstrt}	Zeit für einen Wiederstart der ICE	s
T_{des}	gefordertes Wunschmoment	Nm
T_{EM}	Moment der E-Maschine	Nm
$T_{\text{EM,BN}}$	Moment der E-Maschine zur Deckung des Bordnetzes	Nm
$T_{\text{EM,rec}}$	Rekuperationsmoment der E-Maschine	Nm
T_{ICE}	Moment des Verbrennungsmotors	Nm
$T_{\text{ICE,thrust}}$	Schubmoment des Verbrennungsmotors	Nm
$T_{\text{GB,in}}$	Getriebeeingangsmoment	Nm
$T_{\text{GB,loss}}$	Getriebeverlustmoment	Nm
$T_{\text{GB,out}}$	Getriebeausgangsmoment	Nm
T_R	Raddrehmoment	Nm
U_{HV}	Spannung an der HV-Batterie	V
U_{oc}	Leerlaufspannung	V
v_L	Strömungsgeschwindigkeit	m/s
v_x	Fahrzeuggeschwindigkeit in Längsrichtung	m/s

v_∞	Anströmgeschwindigkeit	m/s
z	Gang	-
α	Fahrbahneigungswinkel	rad
β_h	Schräglaufwinkel Hinterachse	rad
β_v	Schräglaufwinkel Vorderachse	rad
γ_L	Windgeschwindigkeit	m/s
$\eta_{(\cdot)}$	Wirkungsgrad von (\cdot)	%
Θ_{red}	reduziertes Trägheitsmoment	kg · m ²
κ	Kurvenkrümmung	1/m
λ	Schlupf	-
μ_L	Lagerbeiwert	-
ρ	empirischer Korrelationskoeffizient	-
ρ_L	Luftdichte	kg/m ³
τ_a	Außentemperatur	°C
ϕ	Anströmwinkel	°
ψ	Vorspurwinkel	rad
ω_1	Raddrehzahl	1/min
ω_2	Getriebeausgangsdrehzahl	1/min
ω_3	Motordrehzahl (EM)	1/min
ω_3'	Getriebeeingangsdrehzahl	1/min
ω_4	Motordrehzahl (ICE)	1/min

Optimierung und Regelung

Zeichen	Bedeutung
a	Index Beschleunigung
\mathcal{A}	Aktionsraum
b	Zustandsgröße in der Zustandsbox
B	Anzahl der Zustandsboxen
c	Gewichtungsfaktor in der Kostenfunktion
E^+	zurückgeführte Energie
E^-	investierte Energie
F_{emp}	empirischer Wert in der F-Statistik
F_{tab}	tabellarischer Wert in der F-Statistik
g	Index Gang
h	Index Hybridmodus
I	Anzahl der Dimensionen
$J(\cdot)$	Gütefunktional bzw. Kostenfunktion von (\cdot)
J^{fit}	Angepasste Kostenfunktion
J^M	Matrixschreibweise der Kostenfunktion

K	Anzahl der Dimensionen
k	Index für Stufe im Entscheidungsprozess
K	Regelmatrix
L	Anzahl der Zustände
N	Anzahl der Stufen im Entscheidungsprozess / Horizont
O	obere asymptotische Schranke der Komplexität
P	Anzahl der Werte, die eine Steuergröße annehmen kann
P_i	Parameterset der Gewichtungsfaktoren c_i in Kapitel 7
Q	Gewichtungsmatrix
R	Gewichtungsmatrix
R^2	Bestimmtheitsmaß
r	Suchregion um eine Strategie k
s	Index SoC
s_k	Weglänge in einer Stufe k
S	Anzahl der beobachteten Zustände bei der ADP
t_k	Abtastzeit
t_0	Zeit am Anfang der Betrachtung
t_e	Zeit am Ende der Betrachtung
u	Steuergröße
v	Index Geschwindigkeit
\mathcal{W}	Wahrscheinlichkeitsraum
x	Systemzustandsgröße
x_0	Anfangszustand
\mathcal{X}	Zustandsraum
y	Ausgangsgröße
z	Störgröße
Z	Ordnung der Polynomfunktion bei der ADP
δ_v	Fahrschlauchbreite
ε	Residuum bei der ADP
γ	Reduktionsfaktor
λ	Äquivalenzfaktor
μ	Aktion
π	Strategie
Π	Menge aller möglichen Strategien
ρ	Reduktionsfaktor
σ	wegdiskrete Abtastung
τ	zeitdiskrete Abtastung
Θ	geschätzte Kosten bei der ADP
ξ	Schrittkosten

C. Literatur

- [1] *EGE-Regelung 83 - Schadstoffemissionen Kfz der Klassen M1, N1*. <http://www.bmvbs.de/SharedDocs/DE/Anlage/static/ECE/r-83-schadstoffemissionen-kfz-der-klassen-m1--n1-teil-i-pdf.pdf>. – Abgerufen am 22.11.2013
- [2] *Emission Test Cycles*. <https://www.dieselnet.com/standards/cycles/>. – Abgerufen am 24.02.2015
- [3] *Inrix XD™ Traffic*. <http://www.inrix.com/xdtraffic.asp>. – Abgerufen am 26.09.2014
- [4] *ISO 14819-3 Traffic and Travel Information (TTI) - TTI messages via traffic message coding*
- [5] *OpenLR White Paper - An open standard for encoding, transmitting and decoding location reference in digital maps*. <http://www.openlr.org>. – Abgerufen am 24.02.2015
- [6] *TomTom HD Traffic™*. http://www.tomtom.com/en_us/services/live/hd-traffic/. – Abgerufen am 26.09.2014
- [7] *White Paper - Historical Traffic Information*. http://www.tomtom.com/en_gb/licensing/downloads/?WT.Click_Link=top_nav. – Abgerufen am 24.02.2015
- [8] *White paper - How TomToms HD Traffic and IQ Routes data provides the very best routing*. http://www.tomtom.com/lib/doc/download/HDT_White_Paper.pdf. – Abgerufen am 24.02.2015
- [9] AHN, K. ; RAKHA, H. : The effects of route choice decisions on vehicle energy consumption and emissions. In: *Transportation Research Part D* 13 (2008), S. 151–167
- [10] AMBÜHL, D. ; GUZZELLA, L. : Predictive reference signal generator for hybrid electric vehicles. In: *IEEE Transactions on Vehicular Technology* 58 (2009), Nr. 9, S. 4730–4740

- [11] ATKINSON, I. M. ; ADAM, T. B. W. ; DIXON, M. J.: *Traffic Monitoring System*. <http://www.freepatentsonline.com/20040102893.pdf>. Version: 2004. – Abgerufen am 24.02.2015
- [12] BACK, M. : *Prädiktive Antriebsregelung zum energieoptimalen Betrieb von Hybridfahrzeugen*, Universität Karlsruhe (TH), Diss., 2006
- [13] BACKHAUS, K. (Hrsg.): *Multivariate Analysemethoden - Eine anwendungsorientierte Einführung*. Berlin : Springer, 2011
- [14] BANVAIT, H. ; ANWAR, S. ; CHEN, Y. : Energy management in a parallel hybrid electric vehicle with a continuous variable transmission. In: *American Control Conference* Bd. 1, 2009, S. 3938–3943
- [15] BARTELT, B. ; REGNIET, G. ; SCHMIDT, G. : Untersuchungen des repräsentativen Fahrverhaltens von PKW auf Stadt und Landstraßen / Umweltbundesamt. 1994. – Forschungsbericht
- [16] BARTH, M. ; BORIBOONSOMSIN, K. ; VU, A. : Environmentally-Friendly Navigation. In: *Proceedings of the 2007 IEEE Intelligent Transportation Systems Conference (2007)*, Oktober, S. 684–689
- [17] BARTSCH, P. : *Fahrtoptimierung im Energiemanagement-Kontext: Verbrauchsoptimierte Routen für Kraftfahrzeuge*, Gottfried Wilhelm Leibniz Universität Hannover, Diss., 2010
- [18] BECK, R. : *Prädiktives Energiemanagement von Hybridfahrzeugen*. Düsseldorf, Diss., 2011
- [19] BELLMAN, R. : *Dynamic Programming*. Princeton University Press, 1957
- [20] BELLMAN, R. ; DREYFUS, S. : Functional approximations and dynamic programming. In: *Mathematical Tables and Other Aids to Computation*. RAND Corporation, 1959 (13), S. 247–251
- [21] BERTSEKAS, D. P.: *Dynamic Programming and Optimal Control*. Athena Scientific, 1996
- [22] BERTSEKAS, D. P.: *Dynamic programming and optimal control*. Bd. 1.: 3. ed. Belmont, Mass. : Athena Scientific, 2005
- [23] BERTSEKAS, D. P.: *Dynamic programming and optimal control - Approximate Dynamic Programming*. Bd. 2.: 4. ed. Belmont, Mass. : Athena Scientific, 2012
- [24] BERTSEKAS, D. P. ; TSITSIKLIS, J. N.: *Neuro-dynamic programming*. Belmont, Mass. : Athena Scientific, 1996

- [25] BÄKER, B. : Prädiktive Betriebsstrategie für zukünftige Antriebssysteme im Kraftfahrzeug. In: *VDI Tagung Innovative Fahrzeugantriebe Dresden*, 2008, S. 327–336
- [26] BOSCH, C. S. C.: Fernbereichsradarsensor LRR3: Long-Range Radar, 3. Generation. 2009. – Forschungsbericht
- [27] BOUSSON, K. : Single Gridpoint Dynamic Programming For Trajectory Optimization. In: *AIAA Atmospheric Flight Mechanics* (2005)
- [28] BRANDSTAETER, M. ; PRESTL, W. ; BAUER, G. : Functional Optimization of Adaptive Cruise Control Using Navigation Data. In: *2004 SAE World Congress Detroit, Michigan* (2004)
- [29] BROKATE, J. ; ÖZDEMİR, E. D. ; KUGLER, U. : Der Pkw-Markt bis 2040: Was das Auto von morgen antreibt / Deutsches Zentrum für Luft- und Raumfahrt e.V. 2013. – Forschungsbericht
- [30] BUNDESREGIERUNG DEUTSCHLAND: *Regierungsprogramm Elektromobilität, Berlin*. 2011
- [31] BUSCH, R. : *Entwicklung und Realisierung einer vollautomatischen Betriebsstrategie für einen leistungsorientierten Hybridantrieb*, RWTH Aachen, Diss., 1996
- [32] CERBE, T. M. ; KUHNERT, A. ; STRUBE, S. : Fuel Saving Potential of Car Navigation Systems. In: *16th ITS World Congress and Exhibition on Intelligent Transport Systems and Services* (2009)
- [33] CHAIR OF THE DEVELOPMENT OF THE TEST PROCEDURE (DTP): Informal document No.GRPE-66-02. Version: 2013. <http://www.unece.org/fileadmin/DAM/trans/doc/2013/wp29grpe/GRPE-66-02.pdf>. – Forschungsbericht
- [34] CHARLES, V. : Continental: Automatisiertes Fahren kommt so sicher wie ABS und ESC / Pressemitteilung Continental. 2013. – Forschungsbericht
- [35] CHASSE, A. ; POGNANT-GROS, P. ; SCIARETTA, A. : Online implementation of an optimal supervisory control for hybrid powertrains. In: *SAE Paper 2009011868* (2009)
- [36] CHEVALIER, M. ; HEINHEIT, H. ; BENMIMOUN, A. : *Vorausschauende Energiemanagement-Strategien für hybride Antriebssysteme*. expert-Verlag, 2005

- [37] DAHLMANN, D. : Autonomes Fahren: Nicht vor 2020. In: *ct magazin* (2013). <http://www.heise.de/ct/artikel/Autonomes-Fahren-Nicht-vor-2020-2059208.html>. – Abgerufen am 24.02.2015
- [38] DANNENBERG, J. ; BURGARD, J. : Car Innovation - Innovationsmanagement in der Automobilindustrie / Oliver Wyman. 2007. – Forschungsbericht
- [39] DELPRAT, S. ; GUERRA, T. M. ; RIMAU, J. : Optimal control of a parallel powertrain: From a global optimization to a real-time control strategy. In: *555th IEEE Vehicular Technology Conference*, 2002, S. 2082–2088
- [40] DITTMAR, R. ; PFEIFFER, B.-M. : *Modellbasierte prädiktive Regelung*. Oldenbourg Verlag, 2004
- [41] DOPPELBAUER, M. : Hybridkonzepte - Hybride und Elektrische Fahrzeuge / Karlsruher Institut für Technologie - Elektrotechnisches Institut. 2012. – Forschungsbericht
- [42] DORRER, C. ; FRIEDMANN, S. ; REICHAERT, G. ; RIEKER, H. : Ein adaptives Antriebsmanagement zur Verbrauchsreduzierung durch Nutzung telematischer Informationssysteme. In: *VDI-Tagung Innovative Fahrzeugantriebe Dresden*, 1998, S. 591–612
- [43] DR. ING. H.C. F. PORSCHE AG: *Die Panamera Modelle*. Produktkatalog, 2012
- [44] DR. ING. H.C. F. PORSCHE AG: *Die Panamera Modelle*. Produktkatalog, 2014
- [45] DURING, A. E.: *Computational Aspects of Dynamic Programming in Higher Dimensions*, Department of Electrical Engineering, Syracuse University New York, Diss., 1964
- [46] ECKL-DORNA, W. : Verräter. In: *Spiegel Wissen 4* (2014)
- [47] ERNST, C.-S. ; HARTER, C. : CO2-Emissionsreduktion bei Pkw und leichten Nutzfahrzeugen nach 2020 / Institut für Kraftfahrzeuge Strategie und Beratung im Auftrag des Bundesministeriums für Wirtschaft und Energie. 2014. – Forschungsbericht
- [48] ESTEVA MOSSO, C. ; MOTTL, M. ; DE CONINCK, R. ; DUPONT, F. : *Digital maps go vertical: TomTom/Tele Atlas and Nokia/NAVTEQ*. http://ec.europa.eu/competition/publications/cpn/2008_3_70.pdf. – Abgerufen am 24.02.2015
- [49] EWING, M. : iRobot Arrives: Audi Piloted Driving Success at Hockenheimring. In: *ForbesLife* (2014). <http://www.forbes.com/sites/markewing/2014/10/20/irobot-arrives-audi-piloted-driving-success-at-hockenheimring/>. – Abgerufen am 24.02.2015

- [50] F., T. ; ANTONY, P. ; LANGHAMMER, S. ; KUBE, R. ; KÖHLE, S. : Hybridbetriebsstrategien mit elektronischem Horizont - ein Gemeinschaftsprojekt der Daimler AG, der Volkswagen AG und dem ika. In: *17. Aachener Kolloquium Fahrzeug- und Motorentechnik*, 2008
- [51] FELDMANN, J. ; ARMER, P. (Hrsg.) ; FEIGENBAUM, E. A. H. (Hrsg.): *Computers and thought: a collection of articles*. New York [u.a.] : MacGraw-Hill, 1963
- [52] FERNANDEZ, P. C. ; LONG, J. : Grades and other loads effects on on-road emissions: an on-board analyzer study. In: *5. CRC on-Road Vehicle Emission Workshop* (1995)
- [53] FINDEISEN, F. (Hrsg.) ; ALLGÖWER, F. (Hrsg.) ; Proceedings of the 21st Benelux Meeting on Systems and Control (Veranst.): *An Introduction to Nonlinear Model Predictive Control*. 2002
- [54] FLECKNER, M. : *Strategien zur Reduzierung des Kraftstoffverbrauchs für ein Vollhybridfahrzeug*, Aachen, Diss., 2010
- [55] FÖLL, A. ; MÜLLER, M. ; MARTIN, B. ; PANDIT, M. ; WEBER, M. : Predictive Gear Scheduling - Funktionsweise von prädiktiv geregelten Schaltprogrammen mit Berücksichtigung von Fahrzeugumfelddaten. In: *VDI-Tagung Getriebe in Fahrzeugen Friedrichshafen*, 2001, S. 417–436
- [56] FÖLLINGER, O. : *Optimierung dynamischer Systeme*. Oldenbourg Verlag, 1988
- [57] FÖLLINGER, O. : *Regelungstechnik*. VDE-Verlag, 2013
- [58] FRÖBERG, A. ; NIELSEN, L. : Optimal Fuel and Gear Ratio Control for Heavy Trucks with Piecewise Affine Engine Characteristics. In: *5th IFAC Symposium on Advances in Automotive Control*, 2007
- [59] FROELICH, J. ; KRUMM, J. : Route Prediction from Trip Observations. In: *Proceedings of SAE World Congress* (2008)
- [60] FÖRSTER, H.-J. : *Automatische Fahrzeuggetriebe : Grundlagen, Bauformen, Eigenschaften, Besonderheiten*. Berlin : Springer, 1991
- [61] FUHS, A. E.: *Hybrid vehicles and the future of personal transportation*. Boca Raton, Fla. [u.a.] : CRC Press, 2009
- [62] GEIGER, T. : Geisterfahrt mit Bertha. In: *Autobild* (2013). <http://www.autobild.de/artikel/autonome-mercedes-s-klasse-mitfahrt-im-prototyp-4375349.html>. – Abgerufen am 24.02.2015

- [63] GONG, Q. ; LI, Y. ; PENG, R. Z: Trip Based Near Global Optimal Power Management of Plug-in Hybrid Electric Vehicles Using Gas-Kinetic Flow Model. In: *17th IFAC World Congress Seoul*, 2008, S. 4665–4670
- [64] GREIN, F. ; WIEDEMANN, J. : Vorausschauende Fahrstrategien für verbrauchs-senkende Fahrerassistenzsysteme. In: *VDI-Tagung Innovative Fahrzeugantriebe Dresden*, 2004, S. 739–756
- [65] GROSS, J. : *Linear regression*. Berlin : Springer, 2003
- [66] GRÖTZKI, S. : *Untersuchung des Einflusses zukünftiger Real Drive Testverfahren auf Betriebsstrategie und Kraftstoffverbrauch von Plug-In-Hybridfahrzeugen*, Karlsruher Institut für Technologie, Diplomarbeit, 2013
- [67] GU, B. ; RIZZONI, G. : An Adaptive algorithm for hybrid electric Vehicle energy management based on driving pattern recognition. In: *ASME Int. Mechanical Engineering Congress and Expositions*, 2006
- [68] GUZZELLA, L. ; SCIARRETTA, A. : *Vehicle propulsion systems - Introduction to modeling and optimization*. 3. ed. Berlin : Springer, 2013
- [69] HABU, N. : *Method and Apparatus for Optimized Gear Shift Indication*. September 1985
- [70] HACKMANN, W. : Fremderregte Synchronmaschinen im Einsatz als Achshybridantriebe / Continental - TU Darmstadt. Version: Juni 2008. http://www.ew.tu-darmstadt.de/media/ew/vortrge/270608_vortrag_hackmann.pdf. – Forschungsbericht. – Abgerufen am 24.02.2015
- [71] HAKEN, K.-L. : *Grundlagen der Kraftfahrzeugtechnik*. Carl Hanser Verlag München, 2013
- [72] HAMANN, H. ; HEDRICK, J. K. ; RHODE, S. ; GAUTERIN, F. : Tire Force Estimation for a Passenger Vehicle with the Unscented Kalman Filter. In: *IEEE Intelligent Vehicles Symposium*, 2014
- [73] HARTIG, F. : *Globale Optimierung chemischer Reaktoren mit der Iterativen Dynamischen Programmierung*, Hamburg-Harburg, Diss., 1994
- [74] HASEWAND, W. : AVL Cruise, Fahrleistungs- und Verbrauchssimulation. In: *ATZ Automobiltechnische Zeitschrift* 103 (2001), Nr. 5, S. 382–392
- [75] HEISSING, B. H. (Hrsg.): *Fahrwerkhandbuch - Grundlagen, Fahrdynamik, Komponenten, Systeme, Mechatronik, Perspektiven*. Wiesbaden : Vieweg + Teubner, 2008

- [76] HELLSTRÖM, E. ; ASLUND, J. ; NIELSEN, L. : Design of a Well-behaved Algorithm for On-board Look-ahead Control. In: *17th IFAC World Congress*, 2008, S. 3350–3355
- [77] HELLSTRÖM, E. ; IVARSSON, M. ; ASLUND, J. ; NIELSEN, L. : Look-ahead Control for Heavy Trucks to minimize Truip Time and Fuel Consumption. In: *5th IFAC Symposium on Advances in Automotive Control*, 2007
- [78] HEUER, S. : Autonomes Fahren - Der Siegeszug der Assistenten. In: *Mercedes-Benz next* (2013). <http://next.mercedes-benz.com/autonomes-fahren/>
- [79] HOFMAN, T. ; STEINBUCH, M. ; DRUTEN, R. van ; SERRARENS, A. : Rule-based energy management strategies for hybrid vehicles. In: *Int. J. of Electric and Hybrid Vehicles* 1 (2007), Nr. 1, S. 71–94
- [80] HOFMANN, P. : *Hybridfahrzeuge - ein alternatives Antriebskonzept für die Zukunft*. Wien [u.a.] : Springer, 2010
- [81] HOOKER, J. : Optimal Driving for Single-Vehicle Fuel Economy. In: *Transportation Research* 22A (1988), Nr. 3, S. 183–201
- [82] HUANG, W. ; BEVLY, D. ; SCHNICK, S. ; LI, X. : Using 3D road geometry to optimize heavy truck fuel efficiency. In: *Proceedings of the 11th International IEEE Conference on Intelligent Transportation Systems* (2008), S. 334–339
- [83] INAGAWA, T. ; TOMOMATSU, H. ; TANAKA, Y. ; SHIIBA, K. ; YAMAGUCHI, G. : Shift control system development for 5 speed automatic transmission using information from the vehicle's navigation system. In: *Proceedings of the SAE 2002 World Conference*, 2002
- [84] JEANNERET, B. ; MARKEL, T. : Adaptive energy management strategy for fuel cell hybrid vehicles. In: *ASE Paper 1298*, 2004
- [85] JEON, S. ; JO, S. ; PARK, Y. ; LEE, J. : Multi-mode driving control of a parallel hybrid electric vehicle using receding horizon control. In: *IEEE Int. Symposium on Industrial Electronics* (2001)
- [86] JOHANNESSON, L. ; EGARDT, B. : Approximate Dynamic Programming Applied to Parallel Hybrid Powertrains. In: *17th IFAC World Congress* (2008), S. 3374–3379
- [87] JOHANNESSON, L. ; EGARDT, B. ; ASBOGARD, M. : Assessing the Potential of Predictive Control for Hybrid Vehicles PPowertrain using Stochastic Dynamic Programming. In: *8th Int. IEEE Conference on Intelligent Transportation Systems* (2005), S. 366–371

- [88] JOHANNESON, L. ; EGARDT, B. : A novel algorithm for predictive control of parallel hybrid powertrains based on dynamic programming. In: *Advances in Automotive Control 5* (2007), Nr. 1, S. 343–350
- [89] KEULEN, T. van ; DE JAGER, B. ; SERRARENS, A. ; STEINBUCH, M. : Optimal Energy Management in Hybrid Electric Trucks Using Route Information. In: *Int. Conference on Advances in Hybrid Powertrains*, 2008, S. 181–201
- [90] KEULEN, T. v. ; JAGER, A. d. ; KESSELS, J. ; STEINBUCH, M. : Energy management in hybrid electric vehicles - Benefit of prediction. In: *6th IFAC Symposium on Advances in Automotive Control*, 2010, S. 1–6
- [91] KIM, T. ; MANZIE, C. ; WATSON, H. : Fuel Economy Benefits of Lookahead Capability in Mild Hybrid Configuration. In: *17th IFAC World Congress*, 2008, S. 5646–5651
- [92] KLEIN, H. K.: *Heuristische Entscheidungsmodelle : neue Techniken des Programmierens und Entscheidens für das Management*. Wiesbaden, Diss., 1971
- [93] KNOCK, P. ; W., O. A.: Switched Model Predictive Controller for Cruise Control of Heavy Trucks with Heuristic Trajectory Planning. In: *Proceedings of the 6th IFAC Symposium Advances in Automotive Control*, 2010
- [94] KOBAYASHI, Y. ; KIYAMA, N. ; AOSHIMA, H. ; KASHIYAMA, M. : A route search method for electric vehicles in consideration of range and locations of charging stations. In: *IEEE Intelligent Vehicles Symposium (IV)*, 2011
- [95] KREMPL, S. : EU-Parlament: Automatischer Auto-Notruf eCall ab 2015. In: *Heise.de* (2014). <http://www.heise.de/newsticker/meldung/EU-Parlament-Automatischer-Auto-Notruf-eCall-ab-2015-2125118.html>. – Abgerufen am 24.02.2015
- [96] KRUG, H. : *Zur Anwendung mathematischer Programmierung auf die Bestimmung wirtschaftlich optimaler Informationsvorgänge*. Duncker Umbolt Berlin, 1970
- [97] KUBE, R. ; BÖCKL, M. ; HOMMEL, M. ; KÖHLE, S. : Energy Management Strategies for Hybrid Drive Train Systems Using Infrastructure Information. In: *ika-tagung Energy Management Today and Tomorrow Aachen*, 2004
- [98] KUHN, K.-P. ; SAMPER, K. : Reduktion des Kraftstoffverbrauchs durch ein vorausschauende Assistenzsystem. In: *Der Fahrer im 21. Jahrhundert. VDI Berichte 1623* (2001)

- [99] KUTTER, S. : *Eine prädiktive und optimierungsbasierte Betriebsstrategie für autarke und extern nachladbare Hybridfahrzeuge*, Universität Dresden, Diss., 2013
- [100] LANG, T. : *Betriebsstrategien beim Hybridantrieb: Sparen beim Fahren*. <http://auto-presse.de/autonews.php?newsid=183533>. – Abgerufen am 27.01.2015
- [101] LAPIDUS, L. ; LUUS, R. : *Optimal control of engineering processes*. Waltham, Mass. [u.a.] : Blaisdell, 1967 (A Blaisdell book in the pure and applied sciences)
- [102] LARSSON, V. ; JOHANNESSON, L. ; EGARDT, B. : Benefit of Route Recognition in Energy Management of Plug-In Hybrid Electric Vehicles. In: *Proceedings of the 2012 American Control Conference* (2012)
- [103] LARSSON, V. ; JOHANNESSON, L. ; EGARDT, B. : Cubic Spline Approximations of the Dynamic Programming Cost-to-go in HEV Energy Management Problems. In: *IEEE European Control Conference* (2014)
- [104] LARSSON, V. ; JOHANNESSON, L. ; EGARDT, B. S. : Impact of Trip Length Uncertainty on Optimal Discharging Strategies for PHEVs. In: *IFAC Symposium Advances in Automotive Control*, 2010
- [105] LÖBEL, C. : ADF - Framework für Fahrerassistenz- und Sicherheitssysteme. In: *Fisita 2008* Bd. 207, 2008
- [106] LEE, H.-D. ; KOO, E.-S. ; SUL, S.-K. ; KIM, J.-S. ; KAMIYA, M. ; IKEDA, H. ; SHINOHARA, S. ; YOSHIDA, H. : Torque control strategy for a parallel-hybrid vehicle using fuzzy logic. In: *Industry Applications Magazine, IEEE* Bd. 6, 2000, S. 33–38
- [107] LEE, H.-D. ; SUL, S.-K. : Fuzzy-logic-based torque control strategy for parallel-type hybrid electric vehicle. In: *IEEE Transactions on Industrial Electronics* 45 (1998), Nr. 4, S. 625–632
- [108] LIN, C.-C. ; KANG, J.-M. ; GRIZZLE, J. ; PENG, H. : Energy management strategy for a parallel hybrid electric truck. In: *American Control Conference* Bd. 4, 2001, S. 2878–2883
- [109] LIU, J. ; PENG, H. : Model and Control of a Power-Split Hybrid Vehicle. In: *IEEE Transactions on Control Systems Technology* 15 (2008), Nr. 6, S. 1242–1251
- [110] LUDWIG, J. : Elektronischer Horizont - Vorausschauende Systeme und deren Anbindung an Navigationseinheiten. In: *ATZelektronik* 7 (2012), Juni

- [111] LUNZE, J. : *Regelungstechnik*. Bd. 2: Mehrgrößensysteme, digitale Regelung. Berlin : Springer Vieweg, 2013
- [112] LUUS, R. : Application of Dynamic Programming to High-Dimensional Non-Linear Optimal Control Problems. In: *Int. J. of Control* 52, 239-250 (1990)
- [113] LUUS, R. : Optimal Control by Dynamic Programming Using Systematic Reduction in Grid Size. In: *Int. J. of Control* 51, 995-1013 (1990)
- [114] LUUS, R. : Numerical convergence properties of iterative dynamic programming when applied to high dimensional systems. In: *Chemical Engineering Research and Design*, 74, 55-62 (1996)
- [115] LUUS, R. : *Iterative Dynamic Programming*. Chapman & Hall, 2000
- [116] MACIEJOWSKI, J. : *Predictive Control with Constraints*. Prentice Hall, New Jersey, 2002
- [117] MAYER, W. ; WIEDEMANN, J. ; NEUBECK, J. : Fahrwiderstandsbestimmung im realen Fahrbetrieb. In: *ATZ Springer Fachmedien Wiesbaden* (2002), Nr. 5, S. 18–21
- [118] MENDONCA, S. : Connected Car Industry Report / Telefonica. 2014. – Forschungsbericht
- [119] MERTENS, F. : BMW hat andere Vision zum autonomen Fahren. In: *Autogazette* (2014). <http://www.autogazette.de/bmw/diess/autonom/bmw-hat-andere-vision-zum-autonomen-fahren-484354.html>. – Abgerufen am 24.02.2015
- [120] MINETT, C. F. ; SALOMONS, A. M. ; DAAMEN, W. ; AREM, B. van ; KUIJPERS, S. : Eco-routing: comparing the fuel consumption of different routes between an origin and destination using field test speed profiles and synthetic speed profiles. In: *2011 IEEE Forum on Integrated and Sustainable Transportation Systems* (2011), July, S. 32–39
- [121] MITSCHKE, M. ; WALLENTOWITZ, H. : *Dynamik der Kraftfahrzeuge*. Berlin : Springer, 2004
- [122] MÜLLER, M. : *Ein Beitrag zur Entwicklung von Assistenzsystemen für eine vorausschauende Fahrzeugführung im Straßenverkehr*. Shaker, 2005
- [123] MÜLLER, T. : Navigation Data Standard (NDS): Bald Industriestandard? In: *Automobil-Elektronik* 8 (2008), Nr. 6, S. 30–31

- [124] MORIN, T. : Dynamic programming and its applications : proceedings of the Internat. Conference on Dynamic Programming and its Applications, Univ. of British Columbia, Vancouver, British Columbia, Canada, April 14-16, 1977. In: PUTERMAN, M. L. (Hrsg.): *Computational Advances in Dynamic Programming*. New York : Acad. Pr., 1978
- [125] MOSCARITOLO, A. : Google's Self-Driving Car Takes Blind Man for a Ride. In: *PCmag* (2012). <http://www.pcmag.com/article2/0,2817,2402340,00.asp>. – Abgerufen am 24.02.2015
- [126] MURRAY, J. J. ; COX, C. J. ; LENDARIS, G. G. ; SAEKS, R. : Adaptive dynamic programming. In: *IEEE Trans. Syst., Man., Cybern. C*, Bd. 32, 2002, S. 140–153
- [127] MURRAY, J. J. ; COX, C. J. ; SAEKS, R. E.: The adaptive dynamic programming theorem. In: *Stability and Control of Dynamical Systems with Applications Control Engineering* (2003)
- [128] MUSARDO, C. ; STACCIA, B. ; BRITTANI, S. ; GUEZENNEC, Y. ; GUZZELLA, L. ; RIZZONI, G. : An Adaptive Algorithm for Hybrid Electric Vehicles Energy Management. In: *Proc. of FISITA 2004 World Congress Barcelona* (2004), 23.-27. Mai
- [129] NEUNZIG, D. ; BENMIMOUN, A. : Potential der vorausschauenden Fahrerassistenz zur Reduktion des Kraftstoffverbrauchs. In: *11. Aachener Kolloquium Fahrzeug- und Motorentechnik*, 2002, S. 1205–1238
- [130] PAGANELLI, G. ; ERCOLE, G. ; BRAHMA, G. ; GUEZENNEC, Y. ; RIZZONI, G. : A general Formulation for the Instantaneous Control of the Power Split in Charge-Sustaining Hybrid Electric Vehicles. In: *5th Intern. Symposium on Advanced Vehicles Control*, 2000, S. 73–80
- [131] PAGANELLI, G. ; TATENO, M. ; BRAHMA, A. ; RIZZONI, G. ; Y.GUEZENNEC: Control development for a hybrid-electric sport-utility vehicle: strategy, implementation and field test results. In: *American Control Conference*, 2001, S. 5064–5069
- [132] PARK, S. ; RAKHA, H. : Energy and Environmental Impact of Roadway Grades. In: *85th Annual Meeting of Transportation Research Board (06-0628)* (2005)
- [133] PISU, P. ; KOPRUBASI, K. ; RIZZONI, G. : Energy Management and Driveability Control Problems for Hybrid Electric Vehicles. In: *44th IEEE Conference on Decision and Control and 2005 European Control Conference*, 2005, S. 1824–1830
- [134] PONTRYAGIN, L. ; BOLTAYANSKII, V. ; GAMKRELIDZE, R. ; MISHCHENKO, E. : *The mathematical theory of optimal processes*. Wiley, 1962

- [135] POWELL, W. B.: *Approximate dynamic programming - Solving the curses of dimensionality*. Hoboken, NJ : Wiley-Interscience, 2007
- [136] PÜTZ, W. : Die Entwicklung eines neuen, weltweit harmonisierten Testverfahrens (WLTP) für Personewagen. In: *Innovative Fahrzeug-Getriebe, Hybrid & Elektro-Antriebe 11. Interationales CTI Symposium und Expo*, 2012
- [137] PULS, T. : CO₂-Regulierung für PKW - Fragen und Antworten zu den europäischen Grenzwerten für Fahrzeughersteller / Institut der deutschen Wirtschaft Köln. 2013. – Forschungsbericht
- [138] RADKE, T. : *Energieoptimale Längsführung von Kraftfahrzeugen durch Einsatz vorausschauender Fahrstrategien*. Karlsruhe, Diss., 2013
- [139] RAMEPTSHAMMER, M. ; DEIML, M. ; HEESCHE, K. ; HAUPTMANN, W. : Learning IPM - A Driving Strategy for Hybrid Electric Vehicles learns its lessons. In: *5th Symposium Hybrid Electric Vehicles and Energy Management Braunschweig*, 2008, S. 203–220
- [140] REICHART, G. ; FRIEDMANN, S. ; DORRER, C. ; DRECHSEL, S. ; WERMUTH, G. : Potentials of BMW DDrive Assistance to Improve Fuel Economy. In: *Sonderheft der Automobiltechnischen Zeitschrift (ATZ)* (1999)
- [141] RESS, C. ; BALZER, D. ; BRACHT, A. ; DUREKOVIC, S. ; LÖWENAU, J. : *ADASIS Protocol for Advanced In-Vehicle Applications*. <http://www.ertico.com/assets/pdf/ADASISv2-ITS-NY-Paper-Finalv4.pdf>. – Abgerufen am 24.02.2015
- [142] RÖGLINGER, S. ; FACCHI, C. : How Can Car2X-Communication Improve Road Safety / Hochschule Ingolstadt. 2009. – Forschungsbericht
- [143] RHODE, S. ; GAUTERIN, F. : Vehicle Mass Estimation Using a Total Least-Squares Approach. In: *Intelligent Transportation Systems Conference ITSC*, 2012
- [144] RHODE, S. ; GAUTERIN, F. : Online Estimation of Vehicle Driving Resistance Parameters with Recursive Least Squares and Recursive Total Least Squares. In: *IEEE Intelligent Vehicles Symposium*, 2013
- [145] RICHARD BELLMAN, S. D.: *Applied Dynamic Programming*. Princeton University Press, 1962
- [146] SAAR, D. ; HILGENBERG, J. ; OELIGER, D. : Hintergrundpapier: Einführung einer Blauen Plakette zur Minderung der NO₂-Belastung in Städten / Deutsche Umwelthilfe. 2014. – Forschungsbericht

- [147] SAERENS, B. : *Optimal Control Based Eco-Driving*, Leuven, Diss., 2012
- [148] SAERENS, B. ; DIEHL, M. ; BULCK, E. V. ; RE, L. del (Hrsg.) ; ALLGÖWER, F. (Hrsg.) ; GLIELMO, L. (Hrsg.) ; GUARDIOLA, C. (Hrsg.) ; KOLMANOVSKY, I. (Hrsg.): *Optimal Using Pontryagin's Maximum Principle and Dynamic Programmin in Automotive Model Predictive Optimal Control*. Springer, 2010
- [149] SAMPLER, K. ; KUHN, K.-P. : Reduktion des Kraftstoffverbrauchs durch ein vorausschauende Assistenzsystem. In: *VDI Tagung Der Fahrer im 21. Jahrhundert Berlin*, 2001, S. 79–93
- [150] SAWARAGI, Y. ; NAKAYAMA, H. ; TANINO, T. ; BELLMAN, R. E. (Hrsg.): *Theory of Multiobjective Optimization*. Academic Press, 1985
- [151] SCHULZE, P.M.: *Beschreibende Statistik*. München : Oldenbourg, 2003
- [152] SCHWARZ, H. : *Optimale Regelung linearer Systeme*. Bibliograph. Institut, 1988
- [153] SCHWARZKOPF, A. ; LEIPNIK, R. : Control of highway vehicles for minimum fuel consumption over varying terrain. In: *Transportation Research* 11 (1977), Nr. 4, S. 279–286
- [154] SCIARETTA, A. ; GUZZELLA, L. ; BACK, M. : Real-time optimal control strategy for parallel hybrid electric vehicles with on-board estimation of the control parameters. In: *IFAC Symposium on Advances in Automotive Control, Salerno (Italy)*, 2004
- [155] SCIARETTA, A. ; ONDER, L. G. G.: On the Power-Split Control of Parallel Hybrid Vehicles: from Global Optimization towards Real-time Control. In: *at - Automatisierungstechnik* 51 (2003), Nr. 5, S. 195–203
- [156] SCIARRETTA, A. ; GUZZELLA, L. : Optimal Energy-Management Strategies. In: *IEEE Control Systems Magazine*, 2007, S. 60–70
- [157] SEILER, J. : *Betriebsstrategien für Hybridfahrzeuge mit Verbrennungsmotor unter der Berücksichtigung von Kraftstoffverbrauch und Schadstoffemissionen während der Warmlaufphase*, TU München, Diss., 2000
- [158] SEMMLER, D. ; KERNER, J. ; SPIEGEL, L. ; BITSCHKE, O. ; RAUNER, T. ; STACHE, I. ; MARQUES, M. : Der Antriebsstrang des Porsche Panamera S E-Hybrid. In: *34. Internationales Wiener Motorensymposium*, 2013
- [159] SI, J. ; BARTO, A. ; POWELL, W. ; WUNSCH, D. ; WILEY (Hrsg.): *Handbook of Learning Dynamic Programming*. Hoboken, New Jersey, 2004

- [160] SPIEGEL, L. ; SCHUERMANN, M. ; RAUNER, T. ; STACHE, I. : Das Antriebskonzept des neuen Cayenne S Hybrid. In: *19. Aachener Kolloquium Fahrzeug- und Motorentechnik* Bd. 1, 2010, S. 53–74
- [161] STATISTISCHES BUNDESAMT: *GENESIS-Online Datenbank*. <https://www-genesis.destatis.de/genesis/online/logon>. – Abgerufen am 24.02.2015
- [162] STIEGELER, M. : *Entwurf einer vorausschauenden Betriebsstrategie für parallele hybride Antriebsstränge*, Universität Ulm, Diss., 2008
- [163] STIEGLER, M. ; ROHR, S. ; KABAZA, H. : Basic Gear Shifting Method for Automatic Gear Box in Mild-Hybrid Vehicles Using Cost Functions. In: *Electric Vehicle Symposium*, 2005
- [164] STIEGLER, M. ; SAUTER, J. M. L. M. Lindenmaierm ; KABAZA, H. : Impact of improved Cost Function - Based Torque Split Algorithm on Different Drive Train Topologies. In: *IEEE Vehicle Power and Propulsion Conference*, 2006
- [165] SUTTON, R. S. ; BARTO, A. G.: *Reinforcement learning - An introduction*. Cambridge, Mass. [u.a.] : MIT Press, 1999
- [166] TERWEN, S. : *Vorausschauende Längsführung für schwere Lastkraftwagen*, Universität Karlsruhe (TH), Diss., 2009
- [167] TUTUIANU, M. ; MAROTTA, A. ; STEVEN, H. ; ERICSSON, E. ; HANIU, T. ; ICHIKAWA, N. ; ISHII, H. : Development of a World-wide Worldwide harmonized Light duty driving Test Cycle (WLTC) / WLTP DHC Chair. 2014 (GRPE-68-03). – Forschungsbericht
- [168] U-BLOX 6: *Receiver Description*. 2014
- [169] WANG, F.-Y. ; ZHANG, H. ; LIU, D. : Adaptive Dynamic Programming: An Introduction. In: *IEEE Computational Intelligence Magazine* 09 (2009), May, Nr. 1556-603X, S. 39–47
- [170] WERBOS, P. J.: Approximate dynamic programming for real-time control and neural modeling. In: *Handbook of Intelligent Control: Neural, Fuzzy and Adaptive Approaches* (1992)
- [171] WIETZKE, J. ; RUSSLIES, L. : *Verfahren zur Übertragung von codierten TMC-Meldungen in einem Nachrichtenübertragungssystem und Vorrichtung zum Empfang solcher Meldungen*. 2003

-
- [172] WILDE, A. : *Eine modulare Funktionsarchitektur für adaptives und vorausschauendes Energiemanagement in Hybridfahrzeugen*, Technische Universität München, Diss., 2008
- [173] WIPKE, K. ; CUDDY, M. ; BURCH, S. : ADVISOR 2.1 - A User-Friendly Advanced Powertrain Simulation Using a Combined Backward/Forward Approach. In: *IEEE Transactions on Vehicular Technology: Special Issues on Hybrid and Electric Vehicles*, 1999
- [174] WIRTSCHAFTSKOMMISSION DER VEREINTEN NATIONEN FÜR EUROPA: Regelung Nr. 101. Amtsblatt der Europäischen Union. 2012. – Forschungsbericht

D. Veröffentlichungen und betreute Abschlussarbeiten

- [175] BAUER, K.-L. : *Optimierungspotentiale in einer prädiktiven Betriebsstrategie eines Hybridfahrzeugs*, Karlsruher Institut für Technologie, Masterarbeit, 2013
- [176] DOSCH, C. : *Potentialanalyse einer prädiktiven Fahr- und Betriebsstrategie für ein Plug-In Hybridfahrzeug und Vergleich zu bestehenden Ansätzen*, Universität Stuttgart, Masterarbeit, 2014
- [177] KLUCKE, M. : *Analyse und Bewertung einer prädiktiven Betriebsstrategie eines Hybridfahrzeugs im Realbetrieb*, Karlsruher Institut für Technologie, Masterarbeit, 2014
- [178] LABONTE, D. : *Entwicklung eines Modells zur Bestimmung des Energiebedarfs instationärer Vorgänge im hybriden Antriebsstrang für eine prädiktive, energieoptimale Fahrstrategie*, Karlsruher Institut für Technologie, Diplomarbeit, 2012
- [179] MAUL, T. : *A Real-Time Capable Method for the Driving Strategy Optimization of Hybrid Electric Vehicles*, Universität Stuttgart, Diplomarbeit, 2012
- [180] SCHLEGEL, M. : *Entwurf, Implementierung und Validierung eines Fahrzeugmodells für eine intelligente, vorausschauende Fahrstrategie*, Universität Stuttgart, Diplomarbeit, 2013
- [181] WAHL, H.-G. ; BAUER, K.-L. ; GAUTERIN, F. ; HOLZÄPFEL, M. : A Real-time Capable Enhanced Dynamic Programming Approach for Predictive Optimal Cruise Control in Hybrid Electric Vehicles. In: *Intelligent Transportation Systems*, IEEE, 2013, S. 1662 – 1667
- [182] WAHL, H.-G. ; GAUTERIN, F. : An Iterative Dynamic Programming Approach for the Global Optimal Control of Hybrid Electric Vehicles under Real-Time Constraints. In: *Intelligent Vehicles Symposium*, IEEE, 2013, S. 592 – 597
- [183] WAHL, H.-G. ; HOLZÄPFEL, M. ; GAUTERIN, F. : Approximate Dynamic Programming Methods Applied to Far Trajectory Planning in Optimal Control. In: *Intelligent Vehicles Symposium*, IEEE, 2014, S. 1085 – 1090

- [184] WIEBE, J. : *Energieoptimale Trajektorienplanung in einer prädiktiven Betriebsstrategie eines Hybridfahrzeugs*, Karlsruher Institut für Technologie, Masterarbeit, 2014

Karlsruher Schriftenreihe Fahrzeugsystemtechnik (ISSN 1869-6058)

Herausgeber: FAST Institut für Fahrzeugsystemtechnik

Die Bände sind unter www.ksp.kit.edu als PDF frei verfügbar
oder als Druckausgabe bestellbar.

- Band 1** Urs Wiesel
Hybrides Lenksystem zur Kraftstoffeinsparung im schweren Nutzfahrzeug. 2010
ISBN 978-3-86644-456-0
- Band 2** Andreas Huber
Ermittlung von prozessabhängigen Lastkollektiven eines hydrostatischen Fahrentriebsstrangs am Beispiel eines Teleskopladers. 2010
ISBN 978-3-86644-564-2
- Band 3** Maurice Bliesener
Optimierung der Betriebsführung mobiler Arbeitsmaschinen. Ansatz für ein Gesamtmaschinenmanagement. 2010
ISBN 978-3-86644-536-9
- Band 4** Manuel Boog
Steigerung der Verfügbarkeit mobiler Arbeitsmaschinen durch Betriebslasterfassung und Fehleridentifikation an hydrostatischen Verdrängereinheiten. 2011
ISBN 978-3-86644-600-7
- Band 5** Christian Kraft
Gezielte Variation und Analyse des Fahrverhaltens von Kraftfahrzeugen mittels elektrischer Linearaktuatoren im Fahrwerksbereich. 2011
ISBN 978-3-86644-607-6
- Band 6** Lars Völker
Untersuchung des Kommunikationsintervalls bei der gekoppelten Simulation. 2011
ISBN 978-3-86644-611-3
- Band 7** 3. Fachtagung
Hybridantriebe für mobile Arbeitsmaschinen. 17. Februar 2011, Karlsruhe. 2011
ISBN 978-3-86644-599-4

Karlsruher Schriftenreihe Fahrzeugsystemtechnik (ISSN 1869-6058)

Herausgeber: FAST Institut für Fahrzeugsystemtechnik

- Band 8** Vladimir Iliev
Systemansatz zur anregungsunabhängigen Charakterisierung des Schwingungskomforts eines Fahrzeugs. 2011
ISBN 978-3-86644-681-6
- Band 9** Lars Lewandowitz
Markenspezifische Auswahl, Parametrierung und Gestaltung der Produktgruppe Fahrerassistenzsysteme. Ein methodisches Rahmenwerk. 2011
ISBN 978-3-86644-701-1
- Band 10** Phillip Thiebes
Hybridantriebe für mobile Arbeitsmaschinen. Grundlegende Erkenntnisse und Zusammenhänge, Vorstellung einer Methodik zur Unterstützung des Entwicklungsprozesses und deren Validierung am Beispiel einer Forstmaschine. 2012
ISBN 978-3-86644-808-7
- Band 11** Martin Gießler
Mechanismen der Kraftübertragung des Reifens auf Schnee und Eis. 2012
ISBN 978-3-86644-806-3
- Band 12** Daniel Pies
Reifenungleichförmigkeitserregter Schwingungskomfort – Quantifizierung und Bewertung komfortrelevanter Fahrzeugschwingungen. 2012
ISBN 978-3-86644-825-4
- Band 13** Daniel Weber
Untersuchung des Potenzials einer Brems-Ausweich-Assistenz. 2012
ISBN 978-3-86644-864-3
- Band 14** **7. Kolloquium Mobilhydraulik.**
27./28. September 2012 in Karlsruhe. 2012
ISBN 978-3-86644-881-0
- Band 15** 4. Fachtagung
Hybridantriebe für mobile Arbeitsmaschinen
20. Februar 2013, Karlsruhe. 2013
ISBN 978-3-86644-970-1

Karlsruher Schriftenreihe Fahrzeugsystemtechnik (ISSN 1869-6058)

Herausgeber: FAST Institut für Fahrzeugsystemtechnik

- Band 16** Hans-Joachim Unrau
Der Einfluss der Fahrbahnoberflächenkrümmung auf den Rollwiderstand, die Cornering Stiffness und die Aligning Stiffness von Pkw-Reifen. 2013
ISBN 978-3-86644-983-1
- Band 17** Xi Zhang
Untersuchung und Entwicklung verschiedener Spurführungsansätze für Offroad-Fahrzeuge mit Deichselverbindung. 2013
ISBN 978-3-7315-0005-6
- Band 18** Stefanie Grollius
Analyse des gekoppelten Systems Reifen-Hohlraum-Rad-Radführung im Rollzustand und Entwicklung eines Rollgeräuschmodells. 2013
ISBN 978-3-7315-0029-2
- Band 19** Tobias Radke
Energieoptimale Längsführung von Kraftfahrzeugen durch Einsatz vorausschauender Fahrstrategien. 2013
ISBN 978-3-7315-0069-8
- Band 20** David Gutjahr
Objektive Bewertung querdynamischer Reifeneigenschaften im Gesamtfahrzeugversuch. 2014
ISBN 978-3-7315-0153-4
- Band 21** Neli Ovcharova
Methodik zur Nutzenanalyse und Optimierung sicherheitsrelevanter Fahrerassistenzsysteme. 2014
ISBN 978-3-7315-0176-3
- Band 22** Marcus Geimer, Christian Pohlandt
Grundlagen mobiler Arbeitsmaschinen. 2014
ISBN 978-3-7315-0188-6
- Band 23** Timo Kautzmann
Die mobile Arbeitsmaschine als komplexes System. 2014
ISBN 978-3-7315-0187-9

Karlsruher Schriftenreihe Fahrzeugsystemtechnik (ISSN 1869-6058)

Herausgeber: FAST Institut für Fahrzeugsystemtechnik

- Band 24** Roman Weidemann
Analyse der mechanischen Randbedingungen zur Adaption der oszillierenden Hinterschneidtechnik an einen Mobilbagger. 2014
ISBN 978-3-7315-0193-0
- Band 25** Yunfan Wei
Spurführungsregelung eines aktiv gelenkten Radpaars für Straßenbahnen. 2014
ISBN 978-3-7315-0232-6
- Band 26** David Schmitz
Entwurf eines fehlertoleranten Lenkventils für Steer-by-Wire Anwendungen bei Traktoren. 2014
ISBN 978-3-7315-0264-7
- Band 27** Christian Schwab
Beitrag zu einer universellen Baggerschnittstelle zur Übertragung elektrischer und hydraulischer Leistung sowie elektronischer Signale für komplexe Anbaugeräte. 2014
ISBN 978-3-7315-0281-4
- Band 28** Peter Dengler
Untersuchung zum effizienten Betrieb von Hydraulikzylindern in Konstantdrucksystemen unter Verwendung einer Zwischendruckleitung. 2015
ISBN 978-3-7315-0295-1
- Band 29** Manuel Bös
Untersuchung und Optimierung der Fahrkomfort- und Fahrdynamikeigenschaften von Radladern unter Berücksichtigung der prozessspezifischen Randbedingungen. 2015
ISBN 978-3-7315-0310-1
- Band 30** 5. Fachtagung
Hybride und energieeffiziente Antriebe für mobile Arbeitsmaschinen 25. Februar 2015, Karlsruhe. 2015
ISBN 978-3-7315-0323-1
- Band 31** Michael Eckert
Energieoptimale Fahrdynamikregelung mehrmotoriger Elektrofahrzeuge. 2015
ISBN 978-3-7315-0332-3

Karlsruher Schriftenreihe Fahrzeugsystemtechnik (ISSN 1869-6058)

Herausgeber: FAST Institut für Fahrzeugsystemtechnik

- Band 32** Martin Scherer
Beitrag zur Effizienzsteigerung mobiler Arbeitsmaschinen. Entwicklung einer elektrohydraulischen Bedarfsstromsteuerung mit aufgeprägtem Volumenstrom. 2015
ISBN 978-3-7315-0339-2
- Band 33** Rinaldo Arnold
Automatische Abstimmung der Sekundärseite eines dreiphasigen Systems zur berührungslosen induktiven Energieübertragung. 2015
ISBN 978-3-7315-0355-2
- Band 34** Johannes Gültlinger
Kraftübertragung und Fahrbahnverschleiß durch Spikereifen. 2015
ISBN 978-3-7315-0358-3
- Band 35** Thorsten Dreher
Energieeffizienz von Konstantdrucksystemen mit sekundärgeregelten Antrieben beim Einsatz in mobilen Arbeitsmaschinen. 2015
ISBN 978-3-7315-0377-4
- Band 36** Steffen Kölling
Konzeptionelle Untersuchung zur Neigekompensation von Stromabnehmern. 2015
ISBN 978-3-7315-0387-3
- Band 37** Michael Fritz
Entwicklungswerkzeuge für die Fahrzeugklimatisierung von Nutzfahrzeugen. 2015
ISBN 978-3-7315-0384-2
- Band 38** Ralf Oberfell
Stochastische Simulation von Energieflüssen im Nutzfahrzeug. Ein einsatzorientiertes Bewertungs- und Optimierungsverfahren. 2015
ISBN 978-3-7315-0403-0
- Band 39** Christoph Sturm
Bewertung der Energieeffizienz von Antriebssystemen mobiler Arbeitsmaschinen am Beispiel Bagger. 2015
ISBN 978-3-7315-0404-7

Karlsruher Schriftenreihe Fahrzeugsystemtechnik (ISSN 1869-6058)

Herausgeber: FAST Institut für Fahrzeugsystemtechnik

- Band 40** Florian Netter
Komplexitätsadaption integrierter Gesamtfahrzeugsimulationen. 2015
ISBN 978-3-7315-0414-6
- Band 41** Markus Springmann
**Auslegung eines asynchronen Langstatorlinearmotors
mit großem Luftspalt als Straßenbahnantrieb.** 2015
ISBN 978-3-7315-0418-4
- Band 42** Alexander Basler
**Eine modulare Funktionsarchitektur zur Umsetzung einer
gesamtheitlichen Betriebsstrategie für Elektrofahrzeuge.** 2015
ISBN 978-3-7315-0421-4
- Band 43** Hans-Georg Wahl
**Optimale Regelung eines prädiktiven Energiemanagements
von Hybridfahrzeugen.** 2015
ISBN 978-3-7315-0422-1

Diese Arbeit beinhaltet den Entwurf für ein Fahrerassistenzsystem für Hybridfahrzeuge, das die Geschwindigkeitsregelung als auch die Regelung des Energiemanagements optimal übernimmt. Dazu sind performante Optimierungsalgorithmen notwendig, die zum einen die gleichzeitige Betrachtung von mehreren Zielkriterien wie Komfort, Zeit und Effizienz erlauben und zum anderen möglichst geringe Rechenzeiten bei kleinem Speicherbedarf benötigen. Dies wird erreicht, indem die Dynamische Programmierung als numerisches Lösungsverfahren durch iterative, heuristische und approximative Berechnungsformen erweitert wird. Da alle verfügbaren Informationen entlang der Strecke berücksichtigt werden sollen, wird der Ansatz der Modellbasierten Prädiktiven Regelung durch eine Parallelisierung in mehrere Stufen erweitert. In der Simulation wird der entwickelte mehrdimensionale Optimierungsansatz mit der in einem Versuchsfahrzeug installierten Strategie zur Steuerung des Energiemanagements verglichen. Dabei kann der Kraftstoffverbrauch durch eine Streckenvorausschau und ohne Längsregelung um 11% reduziert werden. Wird die Geschwindigkeit in der Optimierung berücksichtigt, kann der Kraftstoffverbrauch um 18% reduziert werden oder die Durchschnittsgeschwindigkeit bei gleichem Verbrauch um 21% erhöht werden. Testfahrten im Versuchsfahrzeug verdeutlichen die Relevanz von genauen Echtzeitverkehrsdaten entlang der Route.

