

Vorausschauende Regelung von Fahrzeugsystemen durch stochastische Vorhersage der Fahrzeugdynamik

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

genehmigte
Dissertation
von

M.Sc. Sebastian Fünfgeld

Tag der mündlichen Prüfung: 14. Juli 2020
Referent: Prof. Dr. rer. nat. Frank Gauterin
Korreferent: Prof. Dr.-Ing. Rüdiger Dillmann

Kurzfassung

Die Verbreitung von Fahrerassistenzsystemen und die zunehmende Digitalisierung im Fahrzeugumfeld führen zu einer neuen Anzahl von verfügbaren Informationen im Fahrzeug. Die vorausschauende Steuerung und Regelung von Fahrzeugsystemen ist ein mögliches Anwendungsfeld für diese Informationen, um eine effizientere und intelligentere Steuerung von Fahrzeugsystemen zu realisieren.

Die für die Regelung solcher Systeme benötigten Größen können dabei meist nur mittelbar aus den vorhandenen Informationen erzeugt werden. In vielen Fällen sind Vorhersagemodelle nötig, um die relevanten Größen abzuleiten. Dies ist zum Beispiel der Fall, wenn für die Steuerung des Systems zukünftige Fahrzeugdynamikgrößen wie die Geschwindigkeit des Fahrzeugs oder die Leistungsanforderung benötigt werden. Um die mit den Vorhersagen verbundene Unsicherheit zu berücksichtigen, wird in dieser Arbeit ein ganzheitlich stochastischer Ansatz zur Generierung von Vorhersagen, basierend auf den vorhandenen Umfeldinformationen, abgeleitet. Darauf aufbauend wird die vorausschauende Regelung von Fahrzeugsystemen mit stochastisch optimalen Regelungsverfahren untersucht. Die Gesamtmethode wird an zwei Systembeispielen implementiert und evaluiert.

Um die Vorhersagegüte und die resultierende Regelgüte ins Verhältnis zu setzen, werden unterschiedliche Vorhersagemodelle als Referenz eingesetzt. Die Untersuchungen zeigen, dass die stochastische Vorhersage mit Umfeldinformationen bessere Resultate liefert, als eine Vorhersage ohne diese Informationen oder ohne Berücksichtigung der Unsicherheiten. Weiterhin zeigt sich die Gesamtmethode als geeignet, um neue Funktionalitäten oder effizientere Regelungsverfahren für unterschiedliche Fahrzeugsysteme umzusetzen.

Die in dieser Arbeit vorgestellten Methoden sind Bausteine für die intelligente Regelung von Fahrzeugsystemen unter Einbezug von Fahrerverhalten und Umfeldinformationen. Die Anwendung und Weiterentwicklung dieser Bausteine

ist ein vielversprechendes Forschungsfeld um Fahrzeugsysteme intelligenter und effizienter einzusetzen und zu steuern.

Abstract

The progress of advanced driver assistance systems and the digital revolution in the vehicular environment lead to an increasing amount of information in the single vehicle. Predictive control of vehicle systems is one of the possible fields of application for this newly accessible information, enabling more efficient and intelligent control of thus systems.

In most cases of predictive control of a vehicle system, the actually needed information has to be derived from the available data. Thus commonly some kind of prediction model is needed for this task, e.g. if the control of the system requires a forecast of the vehicle dynamics including velocity or traction power. To account for the inherit uncertainty when working with predictions, the focus of this work is a throughout stochastic approach of modelling and predicting vehicle dynamics based on the available information (e.g. predictive street data). Based on the stochastic forecasting model, the stochastic optimal control of vehicle systems is investigated. The overall framework is applied to and evaluated upon two exemplary vehicle systems.

To set the prediction accuracy and resulting control performance in perspective, several prediction models are used as reference. The results in this work show, that stochastic forecasts using information on the vehicle surroundings and corresponding control perform better than forecasts without this information or such, disregarding the influence of uncertainty. Furthermore the overall framework shows to be suited to improve control performance or enable new functionalities for existing vehicle systems.

The methods discussed in this work are enabler for for intelligent control of vehicle systems with regard to driver behavior and predictive information. Application and further research on those topics is a promising field of research to contribute to more intelligent and more efficient system behavior for several vehicle systems.

Danksagung

Die vorliegende Arbeit entstand während meiner Tätigkeit in der Abteilung Entwicklung Gesamtfahrzeug Energiemanagement der Dr. Ing. h.c. Porsche AG in Kooperation mit dem Institut für Fahrzeugsystemtechnik des Karlsruher Instituts für Technologie. Im Folgenden möchte ich den zahlreichen Personen, die zu dem Zustandekommen dieser Arbeit beigetragen haben meinen Dank aussprechen.

Mein aufrichtiger Dank gilt Herrn Prof. Dr. rer. nat. Gauterin für die Betreuung dieser Arbeit und die vielen anregenden Diskussionen zur Themenstellung und allen methodischen Herausforderungen.

Des Weiteren danke ich Herrn Prof. Dr.-Ing. Rüdiger Dillmann für die Übernahme des Korreferats und Herrn Prof. Dr.-Ing. Jürgen Fleischer für die Übernahme des Prüfungsvorsitzes.

Dr. Michael Frey danke ich für die zahlreichen Diskussionen und Anregungen während der Bearbeitung des Themas und Dr. Martin Gießler für die Unterstützung beim Aufbau der schriftlichen Ausarbeitung.

Meinen Vorgesetzten bei der Porsche AG, Dr. Frank Weberbauer und Dr. Marc Albrecht, danke ich für das entgegengebrachte Vertrauen und die gegebenen Gestaltungsfreiheit bei der Bearbeitung des Themas, die die Arbeit in dieser Form ermöglicht haben.

Mein besonderer Dank gilt Marc Holzäpfel für das stetige Interesse an der Themenstellung und die zahlreichen tiefgehenden Diskussionen rund um alle herausfordernden mathematischen Probleme im Kontext dieser Arbeit.

Des Weiteren danke ich meinen Doktoranden- und Team-Kollegen für die allgegenwärtige Möglichkeit für Fachsimpelien und das viel Anregung und Freude bereitende Arbeitsumfeld. Unter vielen Anderen möchte ich hier Stefan

Scheubner, Dr. Kai-Lukas Bauer, Henry Patzig, Dr. Hans-Georg Wahl, Dr. Johannes Bach und Adam Thorgeirsson hervorheben.

Meiner Familie und insbesondere meinen Eltern danke ich für die bedingungslose Unterstützung und Förderung meiner akademischen Ausbildung, sowie meinen Eltern und Schwiegereltern für die zahlreichen Stunden des Korrekturlesens dieser Arbeit und anderer Veröffentlichungen.

Zuletzt möchte ich mich bei meiner Frau bedanken, die immer an das Gelingen dieser Arbeit geglaubt hat und mich durch die zahlreichen schwierigen Phasen beim Erstellen dieser Arbeit mit ihrer steten Ermutigung und Unterstützung begleitet hat.

Karlsruhe, im Juli 2020

Sebastian Fünfgeld

Inhaltsverzeichnis

Kurzfassung	i
Abstract	iii
Danksagung	v
1 Einleitung	1
1.1 Motivation	2
1.2 Gliederung der Arbeit	3
2 Grundlagen vorausschauender Steuerung und Regelung .	5
2.1 Vorausschauende Regelung im Fahrzeugkontext	6
2.1.1 Regelung des Fahrzeugs	6
2.1.2 Regelung von Fahrzeugsystemen	7
2.2 Optimalsteuerung und modellprädiktive Regelung	9
2.3 Grundlagen und Prinzipien von Vorhersagen	13
2.3.1 Klassifizierung von Vorhersagen	14
2.3.2 Bewertung von Vorhersagen	16
2.4 Positionierung der Arbeit	17
3 Vorhersage der Fahrzeugdynamik	21
3.1 Relevante Größen der Fahrzeugdynamik	21
3.2 Literaturüberblick Fahrermodellierung	23
3.2.1 Grundlagen der Fahrermodellierung	23
3.2.2 Vorhersagemodelle	27
3.3 Prädiktive Streckendaten	34
3.4 Teststrecke und Messfahrten	35
3.5 Stochastisches Framework zur Fahrzeugdynamikvorhersage .	37
3.5.1 Transferfunktion	38
3.5.2 Stochastische Prozessmodellierung	43

3.6	Parameterinferenz	52
3.6.1	Methodik zur Verifizierung	53
3.6.2	Rekursive Schätzverfahren	55
3.6.3	Ergebnisse der Testfahrten	79
3.7	Erzeugung stochastischer Vorhersagen	81
3.7.1	Monte-Carlo-Sampling und -Approximation	81
3.7.2	Konvergenz und Varianz	84
3.8	Validierung des Vorhersagemodells	88
3.8.1	Bewertungsgrößen	88
3.8.2	Einflussanalyse	91
3.8.3	Referenzmodelle	95
3.8.4	Ergebnisse mit Realfahrdaten	97
3.8.5	Fazit	107
4	Vorausschauende Steuerung von Fahrzeugsystemen	109
4.1	Stochastisch optimale Regelung	109
4.2	Aktive und Adaptive Aerodynamik	110
4.2.1	Systemmodell und Lösung des Optimalsteuerungsproblems	112
4.2.2	Reduktion des Luftwiderstands	114
4.2.3	Performanzorientierte Aerodynamik	119
4.2.4	Fazit	123
4.3	Vorausschauendes Thermomanagement einer elektrischen Maschine	125
4.3.1	Vereinfachtes Systemmodell	127
4.3.2	Modellprädiktive Regelung der Motortemperatur	131
4.3.3	Vergleich PI-Regler und MPC	139
4.3.4	Ergebnisse mit Realfahrten	144
4.3.5	Fazit	147
5	Zusammenfassung und Ausblick	151
A	Anhang	155
A.1	Messfahrten	155
A.2	Zeitdiskrete Auswertung der Fahrzeugbewegungsgleichung	158
A.3	Stationäre Verteilung und mittlere Zustandsaufenthaltszeiten einer Markov-Kette	159
A.4	Rekursive Schätzung von Mittelwert und Varianz	160

A.5	Rekursive Schätzung von Parametern eines AR(1)-Modells . . .	161
A.6	Autokorrelation und -kovarianz eines gefilterten AR(1)-Modells	164
A.7	Verifizierung der Parameterschätzung zur Fahrerwunschkynamik	167
A.8	Berechnung der Wasserstein-Distanz W_p zwischen Sample-Verteilungen	173
A.9	Abbildungen zur Konvergenz der Monte-Carlo-Approximation	174
A.10	Abbildungen zu Abschnitt 3.8.4	176
Nomenklatur		179
	Abkürzungen	179
	Formelzeichen	181
	Mathematische Schreibweisen	185
Literaturverzeichnis		187

1 Einleitung

Das intelligente Fahrzeug. Was vor wenigen Jahren noch Zukunftsvision war, wird – getrieben von den Innovations- und Entwicklungsfeldern in der Automobilindustrie – realisierbar. Unter dem Aspekt *intelligentes Fahrzeug* lassen sich dabei drei wichtige, nicht voneinander zu trennende Innovationsfelder zusammenfassen:

- Hochautomatisiertes und autonomes Fahren
- Das digitalisierte und vernetzte Fahrzeug
- Intelligente Fahrzeug-Funktionen

Hochautomatisiertes und autonomes Fahren ist durch Fortschritte in der Sensor-Technologie und gesteigerte Rechenressourcen im Fahrzeug auf dem Vormarsch. Während Assistenzsysteme älterer Fahrzeuggenerationen rein assistierende Funktionen ausgeübt haben (z.B. Abstandstempomat und Spurhalteassistent), übernehmen Assistenzsysteme der aktuellen Generationen die komplette Fahraufgabe für bestimmte Fahrszenarien (z.B. Autobahn- und Staupilot). Damit rückt auch das teilautonome Fahren greifbar nahe an den Serieneinsatz (KAB16). Das automatisierte Fahren ist dabei ein wichtiger Treiber der zunehmenden **Digitalisierung und Vernetzung** des Fahrzeugs (Sal16). Dabei steht nicht nur die Vernetzung der Fahrzeuge untereinander sowie mit Back-End-Strukturen im Fokus, sondern auch die Vernetzung mit dem Kunden und dessen Unterhaltungselektronik (Bur17). Neben automatisierten Fahrfunktionen profitiert ein weiteres Anwendungsfeld von der zunehmenden Vernetzung und Datenverfügbarkeit: Die **intelligenten Fahrzeug-Funktionen**. Zu diesen zählt zum Beispiel die selbständige Anpassung des Fahrzeugs an sein Umfeld und das Fahrerverhalten (Wes17). Die selbständige Anpassung des Fahrzeugs an die Fahrsituation kann über die vorausschauende Steuerung von Fahrzeugsystemen erfolgen. Unter vorausschauender Steuerung von Fahrzeugsystemen kann dabei jede Form der Steuerung eines Systems verstanden werden, die Informationen über das Umfeld und die kommenden Fahrsituationen berücksichtigt.

1.1 Motivation

Für die vorausschauende Steuerung von Fahrzeugsystemen werden Informationen über das Umfeld benötigt. Zentrales Element dieser Umfeldinformationen sind die über das Navigationssystem bereit gestellten Kartendaten. Ursprünglich nur zur Navigation genutzt, wird heutzutage ein Ausschnitt der Kartendaten (elektronischer Horizont) über Protokolle wie das ADASIS-Protokoll (siehe z.B. (RBB⁺08)) an das übrige Fahrzeug kommuniziert (Lud12).

Im Gegensatz zu vielen Fahrerassistenzsystemen können die Anforderungen für Fahrzeugsysteme nur mittelbar aus den Kartendaten abgeleitet werden. Um die für das System relevanten Informationen zu erhalten, müssen die Kartendaten zunächst interpretiert und mit anderen Informationen zusammengeführt werden, um die relevanten Informationen (zum Beispiel die zukünftige Geschwindigkeit des Fahrzeugs) daraus abzuleiten. Diese Ableitung ist dabei typischerweise eine Vorhersage und meist unmittelbar mit der Interpretation des Fahrerverhaltens bzw. -wunsches verbunden. Bekannte Arbeiten, die sich mit dem Thema der vorausschauenden Steuerung von Fahrzeugsystemen befassen, fokussieren sich dabei auf die Modellierung eines spezifischen Systems und die Ermittlung von Potentialen durch die vorausschauende Steuerung. Der Aspekt der notwendigen Vorhersage wird dabei häufig nur unzureichend beachtet. Dabei ist dieser ein wichtiger Faktor für die tatsächliche Umsetzbarkeit und Zuverlässigkeit solcher Funktionen. Dies ist umso relevanter, da viele Systeme einen ähnlichen Informationsbedarf über die voraus liegende Strecke haben und die Vorhersage somit ein zentrales Element der vorausschauenden Steuerung von Fahrzeugsystemen darstellt.

Ziel dieser Arbeit ist es daher, sich der vorausschauenden Steuerung von der Seite der Vorhersagen zu nähern. Tatsächliche Vorhersagbarkeit und Einfluss der Unsicherheit bleibt bei bisherigen Arbeiten häufig außer Acht, da der Fokus auf der Systemmodellierung und -steuerung liegt. Folglich soll in dieser Arbeit eine systematische Betrachtung der mit Vorhersagen verbundenen Unsicherheit und deren Auswirkung auf die Steuerung von Fahrzeugsystemen vorgenommen werden.

1.2 Gliederung der Arbeit

Die vorliegende Arbeit gliedert sich wie folgt:

In **Kapitel 2** werden Arbeiten in der Literatur zu vorausschauenden Anwendungen im Fahrzeugumfeld sowie die regelungstechnischen Grundlagen der vorausschauenden Steuerung erläutert. Neben den Grundlagen der vorausschauenden Steuerung wird auch eine Einführung in das Themengebiet Vorhersagen gegeben und die Positionierung der Arbeit erläutert.

Kapitel 3 behandelt das spezifische Problem der Vorhersage von Fahrzeugdynamikgrößen. Zunächst werden die relevanten Größen der Fahrzeugdynamik vorgestellt und ein Literaturüberblick zu den Themen Fahrermodellierung und -vorhersagen geben. Auf Basis des Stands der Technik auf dem Gebiet der Vorhersagen und der in der Literatur bekannten Vorhersagemodelle wird eine neue Methodik zur Vorhersage von Fahrzeugdynamikgrößen erarbeitet. Dabei werden zunächst die einzelnen Aspekte der Modellierung diskutiert und anschließend die Adaption der Parameter des Vorhersagemodells mit realen Testfahrten untersucht. Anschließend wird eine Methodik zur Erzeugung von stochastischen Vorhersagen mittels der vorgestellten Modellierung eingeführt und erläutert. Zur Validierung des erarbeiteten Vorhersagemodells werden statistische Bewertungskriterien aus dem Gebiet der Vorhersagen herangezogen und auf das Modell sowie in der Literatur bekannte Referenzverfahren angewendet.

Auf Basis der stochastischen Vorhersage wird in **Kapitel 4** die stochastisch optimale Regelung von unterschiedlichen Systemklassen thematisiert. Dabei werden Lösungsmöglichkeiten des Optimalsteuerungsproblems für Systeme mit diskreten und kontinuierlichen Zuständen behandelt. Diese Lösungsverfahren werden in Verbindung mit den vorgestellten Vorhersagemodellen für zwei Anwendungsbeispiele implementiert. Dabei wird zunächst die vorausschauende Steuerung einer aktiven Aerodynamik als Systembeispiel mit diskreten Zuständen vorgestellt. Neben der aktiven Aerodynamik wird das Thermomanagement einer elektrischen Maschine als weiteres Systembeispiel untersucht. Dafür wird zunächst ein vereinfachtes Systemmodell beschrieben sowie die Lösung des Optimalsteuerungsproblems für dieses System ausgeführt. Die Zielerreichung der daraus resultierenden vorausschauenden Regelung wird für beide System-

beispiele mit den zuvor bereits untersuchten Vorhersagemodellen ermittelt und bewertet.

Kapitel 5 fasst die Ergebnisse der vorliegenden Arbeiten zusammen und gibt einen Ausblick auf mögliche weiterführende Untersuchungen und Anwendungsmöglichkeiten.

2 Grundlagen vorausschauender Steuerung und Regelung

Vorausschauende Regelung ist kein abgegrenztes und klar definiertes Themengebiet. Im Kontext dieser Arbeit wird der Begriff wie folgt abgegrenzt:

Eine vorausschauende Steuerung bzw. Regelung ist ein Verfahren, das Informationen über den zukünftigen Zustand von Eingangsgrößen des Systems (z.B. Wärmeeintrag in einem Kühlsystem) oder zukünftige Änderungen von Systemparametern (wie z.B. der Fahrzeugmasse oder des Luftwiderstandsbeiwerts) und Randbedingungen (wie z.B. Fahrzeugschwindigkeit und dadurch zur Verfügung stehendes Kühlpotential) zur Steuerung und Regelung des Systems verwendet.

Vorausschauende Regelungen bedienen sich häufig, jedoch nicht ausschließlich, der Methodiken der modellprädiktiven Regelung (MPC)¹. Bei modellprädiktiver Regelung wird ein dynamisches Modell des zu regelnden Systems verwendet, um das Verhalten des Systems in Abhängigkeit von möglichen Steuervektoren zu berechnen. Im Sinne der obigen Definition ist MPC aber nur dann als vorausschauende Regelung zu verstehen, wenn dabei auch zukünftige Randbedingungen oder Eingangsgrößen des Systems berücksichtigt werden. Im Gegensatz zu diesem Anwendungsfall kann MPC auch zur Regelung eines komplexen Systems verwendet werden, ohne zukünftige Randbedingungen zu berücksichtigen oder nur unter der vereinfachenden Annahme konstanter Randbedingungen einzubeziehen. In diesem Fall wird nur das Systemverhalten selbst prädiziert, um eine komplexe Regelungsaufgabe zu lösen (Bsp.: Aufschwingen und Stabilisieren eines inversen Pendels (MWN09)). Neben MPC sind auch andere Verfahren, wie zum Beispiel regelbasierte Verfahren, für die vorausschauende Regelung einsetzbar. Im folgenden Abschnitt wird zunächst ein Überblick über bekannte Anwendungen vorausschauender Regelung

¹ Model Predictive Control

im Fahrzeugkontext gegeben, bevor die Grundlagen der modellprädiktiven Regelung näher erläutert werden.

2.1 Vorausschauende Regelung im Fahrzeugkontext

2.1.1 Regelung des Fahrzeugs

Im Fahrzeugkontext ist vorausschauende Regelung besonders im Bereich des assistierten und automatisierten Fahrens von Bedeutung. Diese Problemstellung wird in dieser Arbeit allerdings nicht tiefgehend behandelt. Da viele Herausforderungen beim automatisierten Fahren aber ähnlich mit denen der vorausschauenden Steuerung von Fahrzeugsystemen sind, wird an dieser Stelle ein kurzer Überblick über das Themengebiet gegeben.

Die echtzeitfähige Trajektorienplanung und -regelung für die Längs- und Querrführung des Fahrzeugs wird beispielsweise in (Wer10) und (Bau19) thematisiert. In (Wah15) wird für den Entwurf eines effizienten Fahrerassistenzsystems die Längsführung des Fahrzeugs in Kombination mit der Energiemanagementstrategie eines Hybridfahrzeugs betrachtet. Die Herausforderungen solcher und ähnlicher Problemstellungen liegen dabei vor allem in der Mehrdimensionalität des Zustandsraums des Systems und der Berücksichtigung komplexer Beschränkungen von Systemzuständen und Steuergrößen. In vielen Fällen wird die Sollvorgabe (Bsp.: Fahrtrajektorie) durch ein Optimierungsverfahren ermittelt. Die Trajektorienfolgeregelung und Stabilisierung des Systems kann durch MPC, aber auch andere Verfahren erfolgen (siehe z.B. (PCY⁺16)).

Neben der Planung und Regelung des Fahrzeugs in statischer Umgebung ist das Verhalten in dynamischen Umgebungen eine der aktuellen Herausforderungen auf dem Gebiet des höher automatisierten Fahrens. Hierzu zählen beispielsweise Situationen mit anderen Verkehrsteilnehmern wie zum Beispiel an Kreuzungen und Kreisverkehren, Spurwechsel in dichtem Verkehr oder auch die Reaktion auf Fußgänger und andere dynamische Hindernisse (vgl. (CLS⁺15, OJK⁺16)). Die Herausforderungen in der Beherrschung solcher Situationen unterscheiden sich zum Teil deutlich von der klassischen Trajektorienplanung. Neben der Komplexität der eigentlichen Pfad- und Trajektorienplanung kommen zusätzliche Schwierigkeiten durch Verhaltensinterpretation

und -vorhersage, Berücksichtigung von Interaktionen und Planung in unsicherer Umgebung hinzu.

2.1.2 Regelung von Fahrzeugsystemen

Vorausschauende Regelung hat auch auf dem Gebiet der Steuerung von Fahrzeugsystemen unterschiedliche Anwendungsfelder. Besondere Aufmerksamkeit hat dabei das Energiemanagement von Hybridfahrzeugen bekommen. Während frühe Ansätze hauptsächlich auf heuristische Strategien zurückgegriffen haben (siehe z.B. (Bus96, Sei00)), finden sich in neueren Arbeiten vermehrt optimalsteuerungsbasierte Ansätze (vgl. (Wah15, Bac05, AG09, Maa15)). Ziel einer vorausschauenden Energiemanagementstrategie ist dabei die verfügbare elektrische Energie bzw. den Energiespeicher intelligent zu nutzen, um den Kraftstoffverbrauch des Fahrzeugs zu reduzieren.

Neben dem klassischen Hybrid- bzw. PlugIn-Hybridfahrzeug, wird vorausschauende Regelung auch bei Elektrofahrzeugen mit zwei elektrischen Energiespeichern (Batterie und Superkondensator) untersucht (vgl. (GA17, GTKD17, SHL⁺15, ZXS17)). Der Superkondensator dient dabei dem Ausgleich der kurzen hohen Lastspitzen, während die Batterie die primäre Energiequelle für den dauerhaften Leistungsbedarf darstellt. Eine vorausschauende Energiemanagementstrategie kann dabei helfen, die notwendigen Stromspitzen der Batterie und damit deren Alterungseffekte zu minimieren.

Ein weiteres Anwendungsgebiet für vorausschauende Regelung ist das Thermomanagement des Kraftfahrzeugs. Bei konventionellen Fahrzeugen ist die vorausschauende Kühlsystemregelung schon länger im Fokus und wird z.B. in (Goß09), (BLEK10) und (GS12) thematisiert. Ziel einer solchen Regelung ist das Anheben der mittleren Bauteiltemperaturen, ohne dass die dabei auftretenden Spitzentemperaturen die Auslegungsgrenzen der Bauteile überschreiten (GS12). Weiterhin kann die vorausschauende Absenkung des Temperaturniveaus für besseres Ansprechverhalten und damit eine gesteigerte Dynamik genutzt werden (BLEK10). Durch die zunehmende Bedeutung rein elektrisch angetriebener Fahrzeuge (E-Fahrzeuge) werden auch im elektrischen Antriebsstrang die Verbesserungspotentiale durch vorausschauendes Thermomanagement untersucht (siehe z.B. (Aue15)). Besonderer Fokus liegt hierbei auf der Steigerung der Reichweite des E-Fahrzeugs durch Reduktion des Gesamtener-

giebedarfs. In (Aue15) werden hierfür Maßnahmen zur Vorkonditionierung des Fahrzeugs, aber auch die adaptive Regelung während der Fahrt durch vorausschauende Adaption von Regelparametern diskutiert. Von (AEJ17) wird weiterhin ein vorausschauender Ansatz zur elektrischen und thermischen Regelung eines Batteriepacks vorgestellt.

Weitere mögliche Anwendungsgebiete für vorausschauende Steuerungen und Regelungen sind zum Beispiel das Leistungsmanagement in Fahrzeugbordnetzen ((Koh13)) oder vorausschauende Schaltstrategien für Automatikgetriebe (vgl. (NHSS11, RSA14)).

Für die oben genannten Anwendungsbeispiele werden vor allem Größen benötigt, die nur mittelbar aus den Umgebungsinformationen abgeleitet werden können. Im Fall des Energiemanagements sind dies beispielsweise die Fahrzeuggeschwindigkeit v , die Fahrzeuglängsbeschleunigung a_x und die Radleistungsanforderung P_R (siehe z.B. (Bac05, AG09, BRD⁺10, Maa15)). Die Anwendung von optimalsteuerungsbasierten Ansätzen für vorausschauende Regelungen erfordert somit die Vorhersage von Umgebungsgrößen. In diesem Punkt unterscheidet sich die vorausschauende Steuerung maßgeblich von klassischer MPC. Bei klassischer modellprädiktiver Regelung wird nur die Systemreaktion auf zukünftige Steuergrößen prädiziert, die Umgebungseinflüsse werden aber als konstant angenommen. Die Unsicherheit der Vorhersage ist hier somit auf Modell- und Messunsicherheiten beschränkt.

Die Notwendigkeit einer Vorhersage für die vorausschauende Steuerung wirft zwei grundlegende Fragen auf:

- Welche Möglichkeiten gibt es, mit der Unsicherheit einer Vorhersage umzugehen?
- Welche Auswirkungen hat die Unsicherheit auf die Formulierung bzw. Lösung des Optimalsteuerungsproblems?

Bekannte Arbeiten auf dem Gebiet befassen sich häufig mit der Modellierung des Systems und dem Entwurf und der Potentialuntersuchung einer vorausschauenden Regelung. Die Vorhersageproblematik wird dabei oft außer Acht gelassen, beispielsweise durch Annahme bekannter Zukunft (siehe z.B. (NHSS11, Aue15)) oder als Gegenstand zukünftiger Forschungsinteressen benannt (vgl. (Bac05)).

Regelungsverfahren mit einer expliziten Berücksichtigung der Unsicherheit wurden bisher vor allem am Energiemanagement von Hybridfahrzeugen untersucht (vgl. (BRD⁺10, DBBK14, JAE07, MFCS11, RBD⁺10)). Die Komplexität der Lösungssuche des stochastischen Problems kann dabei signifikant höher sein als bei einer deterministischen Problemformulierung. In zahlreichen dieser Arbeiten wird das Fahrerverhalten bzw. die Vorhersagegröße über eine Markov-Ketten-Formulierung abgebildet bzw. vorhergesagt (siehe z.B. (BRD⁺10, LPG04, DBBK14, KF09)).

Um den Zusammenhang und die Relevanz von Unsicherheiten im Zusammenhang mit vorausschauender Steuerung zu erörtern, werden im Folgenden zunächst die Grundlagen der Optimalsteuerung und modellprädiktiven Regelung sowie Vorhersagen im Allgemeinen behandelt.

2.2 Optimalsteuerung und modellprädiktive Regelung

Modellprädiktive Regelung wurde in den 1980er Jahren besonders in der Steuerung von Großanlagen der Chemie- und Ölindustrie populär (ML99, QB03). Die dabei adressierten Problemstellungen zeichnen sich durch mehrdimensionale Regelungsprobleme mit vielen Ein- und Ausgangsgrößen sowie komplexen Systembeschränkungen aus, die bis dahin durch viele verschachtelte und verbundene Regelkreise gesteuert wurden. Heutzutage wird modellprädiktive Regelung auf zahlreichen Anwendungsgebieten eingesetzt. Ein Überblick über die historische Entwicklung und Methoden von MPC findet sich unter anderem in (May14) und (ML99).

Bei MPC wird das Systemverhalten üblicherweise durch eine zeitdiskrete Übertragungsfunktion f_s beschrieben mit

$$x_{t+1} = f_s(x_t, u_t, z_t), \quad (2.1)$$

wobei x_t der aktuelle Systemzustand, u_t die Stell- oder Eingangsgröße und z_t der Zustand einer Störgröße ist. Im Zusammenhang mit vorausschauender Regelung ist die Störgröße des Systems häufig der Zustand einer Umgebungsvariablen, die keine Zustandsgröße eines zu optimierenden Teilsystems ist, deren Verhalten aber für die Ableitung von Steuerungsaktionen relevant ist. Während

das zukünftige Verhalten des Systemzustands x_t bei Kenntnis von u_t und z_t mit der Übertragungsfunktion f_s ermittelt werden kann, ist für die Störgröße z_t ein externes Vorhersagemodell notwendig. Im Folgenden wird daher die Störgröße z_t durch die für Vorhersagegrößen gebräuchliche Notation y_t ersetzt.

Das Regelungsziel wird bei MPC durch eine mathematische Zielfunktion V_T definiert. Bei begrenztem Zeithorizont T (Vorhersage- bzw. Optimierungshorizont) wird die Zielfunktion definiert als

$$V_T = J_f(x_T, y_T) + \sum_{t=0}^{T-1} J_s(x_t, u_t, y_t) \quad (2.2)$$

mit der Schrittgüte J_s und den Terminierungskosten J_f . Mit der Zielfunktion V_T wird das Optimalsteuerungsproblem definiert, wobei die Entscheidungsvariable dabei in den meisten Fällen eine Folge von Stellgrößen ist. Das Optimalsteuerungsproblem definiert sich hier wie folgt:

$$V^* = \min_{u_{0:T-1}} V_T \quad (2.3a)$$

$$\text{u. d. N.: } x_t = f_s(x_{t-1}, u_{t-1}, y_{t-1}), \quad \forall t \quad (2.3b)$$

$$u_t \in \mathcal{U}, x_t \in \mathcal{X} \quad \forall t. \quad (2.3c)$$

\mathcal{U} und \mathcal{X} sind dabei die jeweiligen zulässigen Wertemengen für die Steuergröße u und den Systemzustand x . Die zu dem optimalen Wert V^* der Zielfunktion gehörige Steuerfolge wird im Folgenden als $u_{0:T-1}^* = \{u_0^*, \dots, u_{T-1}^*\}$ bezeichnet². Die optimale Steuerfolge \underline{u}^* ergibt sich entsprechend mit

$$\underline{u}^* = u_{0:T-1}^* = \arg \min_{u_{0:T-1}} V_T. \quad (2.4)$$

Während das Optimalsteuerungsproblem somit über einen Zeithorizont T definiert ist, wird meist nur der erste Wert der resultierenden Steuerfolge u_0^* zur Steuerung des Systems verwendet (One-Step MPC) (siehe Abb. 2.2). Im nachfolgenden Zeitschritt wird das Optimalsteuerungsproblem mit einem dann

² Sequenzen und Folgen werden zur einfacheren Lesbarkeit mit der Notation \underline{x} gekennzeichnet. Wird die Folge mit einem konkreten Indexbereich angegeben, wird die Index-Notation $x_{1:T}$ mit $x_{1:T} = \{x_1, \dots, x_T\}$ verwendet.

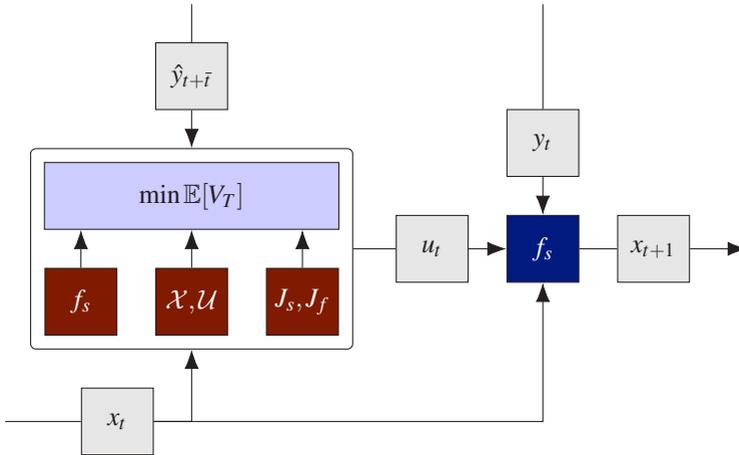


Abb. 2.2: Schematische Darstellung von One-Step-MPC mit Systemzustand $x_t \in \mathcal{X}$ und Systemübertragungsfunktion f_s , Optimalsteuerungsproblem $\min \mathbb{E}[V_T]$, Umgebungszustand y_t und dessen Vorhersage $\hat{y}_{t+\bar{t}}$ sowie berechneter Stellgröße $u_t \in \mathcal{U}$ und daraus folgender Systemzustand x_{t+1} .

Stochastische Optimalsteuerung

Soll die Unsicherheit der Vorhersage in der Optimalsteuerung berücksichtigt werden, kann das Optimierungsproblem auch mit einer Verteilungsvorhersage \hat{Y} formuliert werden. Da im allgemeinen Fall der Systemzustand x abhängig von der Umgebungsvariablen y ist, stellt sich dann auch der Systemzustand im Optimalsteuerungsproblem als Verteilung X dar ³.

Da die Umgebungsgröße (und ggf. der Systemzustand) nur mit einer gewissen Unsicherheit vorhergesagt werden kann, muss die Zielfunktion durch ein statistisches Maß ersetzt werden. Für das stochastische Problem ist es üblich die Zielfunktion V_T aus Gl. (2.2) durch ihren Erwartungswert $\mathbb{E}[V_T]$ zu ersetzen mit

$$\mathbb{E}[V_T] = \mathbb{E}[J_f(X_T, \hat{Y}_T)] + \sum_{t=0}^{T-1} \mathbb{E}[J_s(X_t, u_t, \hat{Y}_t)] . \quad (2.5)$$

³ Der Systemzustand x ist durch den Einfluss der unsicheren Vorhersage \hat{Y} zwar ein Schätzwert, hängt aber bei Vernachlässigung der Unsicherheit der Systemübertragungsfunktion deterministisch von der Vorhersage \hat{Y} ab. Daher wird die Verteilung X hier ohne „ $\hat{\cdot}$ “ notiert.

Das stochastische Optimalsteuerungsproblem ist somit im Allgemeinen durch

$$V^* = \min \mathbb{E}[V_T] \quad (2.6)$$

definiert. Eine auf diesem Optimalsteuerungsproblem basierende Regelung wird auch stochastisch modellprädiktive Regelung (SMPC) genannt. Ein Überblick über das Themengebiet SMPC findet sich unter anderem in (May14) und (Mes16).

Im Gegensatz zum deterministischen Optimalsteuerungsproblem kann eine Steuerfolge u als Optimierungsvariable unzureichend für das stochastische Problem sein. Um die Optimalität der Regelung zu gewährleisten, muss die Optimierungsvariable vielmehr ein Regelgesetz (z.B. eine Abfolge von zeitdiskretisierten Regelgesetzen $\{v_0(\cdot), v_1(\cdot), \dots, v_T(\cdot)\}$) sein. Dieser Fakt wird aus praktischen Gesichtspunkten jedoch häufig außer Acht gelassen. (May14)

Im Sonderfall linearer Systeme mit additivem weißem Rauschen als Stör- bzw. Umgebungsgröße und quadratischer Schrittweiten J_s , ist die Lösung des deterministischen Problems bei Verwendung des Erwartungswerts der Vorhersage identisch mit der Lösung des stochastischen Problems. Diese Eigenschaft wird als *certainty equivalence property* bezeichnet (vW81).

2.3 Grundlagen und Prinzipien von Vorhersagen

Vorhersagen (auch Prognose oder Prädiktion) sind ausgiebiger Forschungsgegenstand im Bereich der Statistik, den Anwendungsgebieten Finanzwirtschaft und Ökonomie (siehe z.B. (TW00, GN14)) sowie der Meteorologie (siehe z.B. (FRG⁺11, ZBW⁺13)). Allgemeine Grundlagen zu Vorhersagen finden sich unter anderem in (Arm01), (Die07) und (BD16). Vorhersagen spielen auch eine wichtige Rolle im Umfeld des autonomen Fahrens, beispielsweise in der Vorhersage der Bewegung von Objekten (CLS⁺15). Im Folgenden wird ein kurzer Überblick über die Grundlagen und Prinzipien von Vorhersagen gegeben.

2.3.1 Klassifizierung von Vorhersagen

Auf oberster Ebene lassen sich Vorhersagen zunächst in zwei Kategorien aufteilen: Qualitative und quantitative Vorhersagen. Im technischen Zusammenhang sind vor allem quantitative Vorhersagen von Interesse, welche daher weiter beleuchtet werden. Bei den Methoden der quantitativen Vorhersagen lassen sich erklärende Modelle und Zeitreihen unterscheiden (Hyn11). **Zeitreihen** nutzen ausschließlich die Information der vorherzusagenden Variablen selbst, um Muster und Zusammenhänge im zeitlichen Verhalten der Variablen zu identifizieren. Sei y_t der Zustand der Variablen zum Zeitpunkt t , dann lässt sich eine Zeitreihen-Vorhersage in einer Form

$$\hat{y}_{t+1} = f(y_t, y_{t-1}, y_{t-2}, \dots) \quad (2.7)$$

schreiben (siehe Abb. 2.3). Beispiele für eine Zeitreihenmodellierung sind ARIMA-Modelle (Autoregressive Integrated Moving Average) oder exponentielle Glättung (GH06).

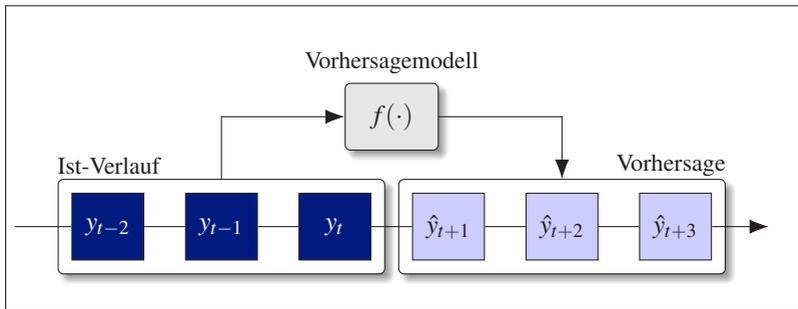


Abb. 2.3: Prinzip-Darstellung einer Vorhersage \hat{y} mittels Zeitreihenmodellierung der Variablen y .

Erklärende Modelle hingegen nutzen einen Zusammenhang zu anderen Informationen (Einfluss- oder Prädiktorvariablen) um Aussagen über das zukünftige Verhalten der vorherzusagenden Größe zu treffen. Sehr häufig wird eine Kombination beider Kategorien angewendet, also z.B. in einer Form

$$\hat{y}_{t+1} = f(y_t, y_{t-1}, \dots, e_t, e_{t-1}, \dots) \quad (2.8)$$

mit der Prädiktorvariablen e (siehe Abb. 2.4).

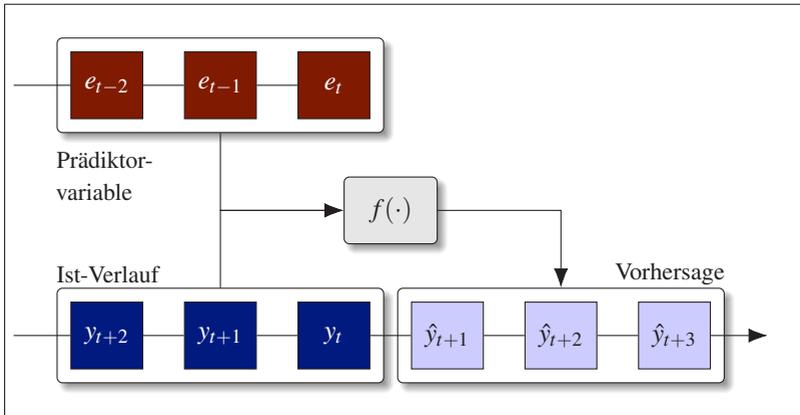


Abb. 2.4: Prinzip-Darstellung einer Vorhersage \hat{y} mittels eines erklärenden Modells und einer Prädiktorvariablen e .

Werden Prädiktorvariablen verwendet, deren Zustände auch in der Zukunft bekannt sind, kann das erklärende Modell auch diese Informationen für eine Vorhersage miteinbeziehen (siehe Abb. 2.5). Beispiele für solche Prädiktorvariablen können z.B. Umgebungsbedingungen sein, die sich aus Kartendaten ableiten lassen und dann auch im Voraus bekannt sind.

Es ist offensichtlich, dass Vorhersagen zwangsläufig mit Unsicherheit verbunden sind. Gerade bei quantitativen Vorhersagen stellt sich häufig die Frage nach der Wahrscheinlichkeitsverteilung für die zu vorhersagende Größe, um diese Unsicherheit bewerten zu können. Quantitative Vorhersagen lassen sich daher weiter nach Punktvorhersagen (Vorhersage eines konkreten Wertes \hat{y}_{t+1}), Intervallvorhersagen (Vorhersage eines Intervalls, z.B. $\hat{y}_{t+1} \pm \sigma_y$) und Verteilungsvorhersagen (Vorhersage der konkreten Verteilung, z.B. durch eine Normalverteilungsfunktion) unterscheiden (Hyn11). Die Vorteile von Verteilungsvorhersagen gegenüber Punktvorhersagen sind eng mit der Problemstellung der Bewertung von Vorhersagen verbunden und werden daher im nächsten Abschnitt diskutiert.

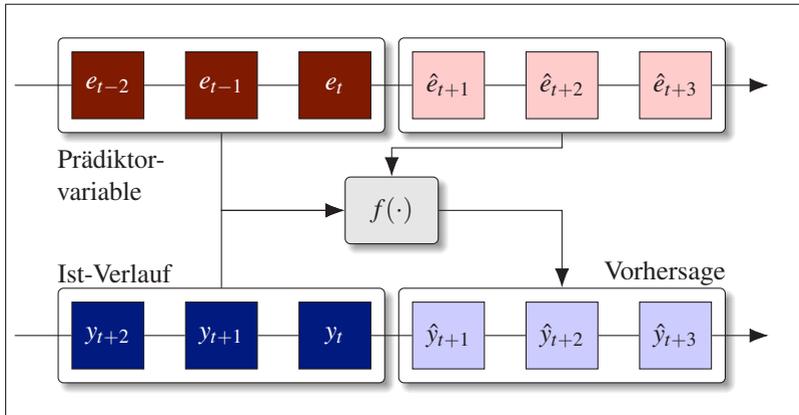


Abb. 2.5: Prinzip-Darstellung einer Vorhersage \hat{y} mittels eines erklärenden Modells und einer auch im Voraus verfügbaren Prädiktorvariablen e (Vorausschaudaten).

2.3.2 Bewertung von Vorhersagen

Im Zusammenhang mit der Unsicherheit einer Vorhersage stellt sich unmittelbar die Frage nach der Güte einer Vorhersage bzw. nach der optimalen Vorhersage. Entgegen der häufigen Annahme, dass der bedingte Mittelwert der tatsächlichen Verteilung die beste Vorhersage ist, lässt sich zeigen, dass die optimale Punktvorhersage bei gegebener Wahrscheinlichkeitsverteilung immer abhängig von der angelegten Bewertungsfunktion ist (vgl. (TW00)). Diese Aussage ist besonders brisant, da häufig angelegte Gütemaße wie der mittlere absolute Fehler (MAE), mittlere relative Fehler (MRE) oder mittlere absolute Prozentfehler (MAPE) systematische Vorhersagefehler favorisieren können. GNEITING (Gne11) zeigt dies beispielhaft in einer simulativen Studie.

Ebenfalls erläutert wird diese Problematik in (EMW09): Die Autoren weisen hier darauf hin, dass häufig nach der besten Vorhersage gefragt wird, ohne dabei die angelegte Bewertungsfunktion zu nennen. Was die beste Vorhersage zu der subjektiven Verteilung des Vorhersagenden ist (z.B. Mittelwert, Median oder Modalwert), hängt dabei jedoch von eben dieser Bewertungsfunktion ab.

Eine Schlussfolgerung dieser Abhängigkeit von optimaler Punktvorhersage und Bewertungs- bzw. Verlustfunktion ist, dass unterschiedliche Interessen

von Nutzern einer Vorhersage den Einsatz von Verteilungsvorhersagen erfordern (TW00). Adressiert eine Vorhersage unterschiedliche Nutzer, kann eine Punktvorhersage nicht die gewünschte Information für alle Nutzer liefern. Es wurde in der Literatur daher schon vielfach argumentiert, dass Vorhersagen im Allgemeinen in der Form von Verteilungsvorhersagen erfolgen sollten (vgl. (DGT98, Gne08, GW13)).

Diese Argumentation lässt sich direkt auf das Optimalsteuerungsproblem übertragen, da die Abhängigkeit von Verlustfunktion und optimaler Vorhersage sich auf die Lösung des Optimalsteuerungsproblems auswirkt. Schließlich ist die Zielfunktion des Optimalsteuerungsproblems nichts anderes als die angelegte Bewertungsfunktion eines Anwenders der Vorhersage (in diesem Fall die Optimalsteuerung). D.h.: Der Einsatz einer Punktvorhersage in einem Optimalsteuerungsproblem führt selbst bei idealer Vorhersage mit dem Mittel- oder Erwartungswert der Verteilung nicht zwangsläufig zur tatsächlichen Optimierung der Zielfunktion bezogen auf die unsicherheitsbehaftete Realisierung der System- und Umgebungszustände. Da die Zielfunktion systemabhängig ist, lässt sich weiter ableiten, dass bei gleichzeitiger Adressierung mehrerer Systeme (mehrere Anwender der Vorhersage) nur durch eine Verteilungsvorhersage die geforderte Information transportiert wird. Die Berücksichtigung der Unsicherheit über eine stochastische Formulierung der Vorhersage und eine daraus folgende stochastische Formulierung des Optimalsteuerungsproblems ist aus mathematischer Sicht somit unerlässlich für die zuverlässige vorausschauende Steuerung von Systemen.

2.4 Positionierung der Arbeit

Zahlreiche Arbeiten haben sich der vorausschauenden Steuerung diverser Fahrzeugsysteme gewidmet. Der Fokus der bekannten Arbeiten liegt dabei meist auf der Modellierung des Systems und dem Potentialnachweis einer vorausschauenden Regelung. Tabelle 2.1 zeigt eine Übersicht von Arbeiten zur vorausschauenden Regelung von Fahrzeugsystemen.

In der Mehrzahl der Fälle, wird MPC zur vorausschauenden Regelung eingesetzt, was im Regelfall eine Vorhersage von Umgebungs- oder Eingangsgrößen des Systems erfordert. Klassifiziert man die Arbeiten nach den verwendeten Vorhersagemodellen (siehe Tabelle 2.2), lassen sich zwei Aspekte feststellen.

Tabelle 2.1: Literaturüberblick vorausschauende Steuerung von Fahrzeugsystemen

Energie-management von Hybridfahrzeugen*	Thermo-management**	Elektrofahrzeuge mit Dual-Energiequelle	Sonstige
(AG09, Bac05, BMF10, BRD ⁺ 10, CB11, Cas13, DLK ⁺ 13, DBBK14, GLP08, JAE07, KF09, LYY ⁺ 16, MSDS12, PDCC13, Maa15, MFCS11, RBD ⁺ 10, Wah15, Wil09, ZW15, ZV12)	(AEJ17, Aue15, AWWK15, Goß09, GS12)	(GA17, GTKD17, SHL ⁺ 15, ZXS17)	(Koh13, RSA14, VSP06)

* Teilweise auch unter Einbezug des thermischen Verhaltens von Antriebsstrang und Batterie.

** Sowohl des Verbrennungsmotor, als auch des elektrischen Antriebsstrangs oder der Batterie.

In einigen Fällen, wird die Aufgabenstellung der Vorhersage überhaupt nicht behandelt und außer Acht gelassen (Annahme einer perfekten Vorhersage). Dies mag ein zulässiger Schritt sein, um zunächst das grundsätzliche Potential einer vorausschauenden Regelung zu erörtern. Aus der Perspektive der Anwendbarkeit ist diese Vernachlässigung jedoch im Allgemeinen unzulässig. In den Arbeiten, die keine Unsicherheiten im Regelungsverfahren selbst betrachten, finden sich auch zahlreiche Beispiele für Zeitreihenmodelle oder erklärende Vorhersagemodelle, die auf Strecken- und Verkehrsdaten oder andere externe Datenquellen zugreifen.

Im Falle einer stochastischen Betrachtungsweise (Berücksichtigung der Unsicherheiten im Regelungsverfahren) werden ausschließlich Zeitreihenmodelle (häufig Markov-Ketten) für die Vorhersage eingesetzt.

Die Literaturübersicht zeigt, dass der Zusammenhang von Vorhersage und Optimalsteuerung im Kontext der vorausschauenden Steuerung von Fahrzeugsystemen bisher nur oberflächlich betrachtet wurde. In vielen Arbeiten aus der Literatur wird die Unsicherheit als Einflussgröße außer Acht gelassen. Wie in Abschnitt 2.3 erläutert, darf dies aber gerade bei Verwendung von Optimalsteuerungsverfahren (Optimierung einer Bewertungsfunktion) nicht vernachlässigt werden. In den Arbeiten, die stochastische Verfahren zur Regelung einsetzen,

Tabelle 2.2: Klassifizierung von Arbeiten nach Vorhersagemethode und Berücksichtigung von Unsicherheiten

		Unsicherheit berücksichtigt in MPC?	
		nein	ja (SMPC)
Vorhersagemodell	Perfekte Vorhersage (bekannte Zukunft)	(AEJ17, Aue15, AWWK15, GA17, NHSS11)	
	Zeitreihenmodell	(DLK ⁺ 13, GA17, VSP06, ZV12, ZXS17) *	(BMF10, BRD ⁺ 10, DBBK14, JAE07, KF09, LYY ⁺ 16, MFCS11, RBD ⁺ 10, ZW15)
	Streckendaten, Verkehrsdaten, etc.	(AG09, Bac05, CB11, Cas13, GLP08, RSA14, Wah15, ZV12)	

* In dieser Klassifizierung wird auch die Annahme, dass die Vorhersagevariable konstant bleibt, als Zeitreihenmodell eingeordnet.

werden verfügbare Daten (wie z.B. Streckendaten) nicht berücksichtigt und ausschließliche Zeitreihenmodelle zur Vorhersage verwendet, die keinerlei externe Informationen in die Vorhersage miteinbeziehen. Dies erscheint wiederum eine unnötiger Verzicht auf Informationsgehalt in den Vorhersagen zu sein.

Da die Vorhersage von Fahrzeugdynamikgrößen eine Voraussetzung für viele Anwendungen ist, soll in dieser Arbeit eine systematische Behandlung dieses Themas stattfinden. Dabei sollen Unsicherheiten in der Vorhersage und Regelung explizit betrachtet und berücksichtigt werden. Im Gegensatz zur Literatur soll bei der Generierung der Vorhersagen dabei jedoch auf die verfügbaren Streckeninformationen zurückgegriffen werden. Basierend auf dem Vorhersagemodell soll anschließend eine vorausschauende Steuerung unterschiedlicher Fahrzeugsysteme aufgebaut werden. Um die unterschiedlichen Aspekte im Zusammenspiel zwischen Vorhersage und Optimalsteuerung zu untersuchen, sollen dabei reale Messfahrten mit unterschiedlichen Fahrern angewendet werden und die Auswirkungen von verschiedenen Vorhersagemethoden verglichen werden.

3 Vorhersage der Fahrzeugdynamik

Für zahlreiche Anwendungen im Umfeld der Steuerung von Fahrzeugsystemen sind fahrdynamische Größen relevant. Die Fahrzeugdynamik umfasst dabei kinetische wie kinematische Größen der Fahrzeugbewegung. Unter Vorhersage der Fahrzeugdynamik wird die Vorhersage der im Folgenden beschriebenen Fahrzeugdynamikgrößen verstanden.

3.1 Relevante Größen der Fahrzeugdynamik

Nachdem im vorherigen Kapitel die Grundlagen von Vorhersagen im Allgemeinen thematisiert wurden, wird in diesem Abschnitt das spezifische Problem der Vorhersage der relevanten Fahrzeugdynamikgrößen behandelt. Diese bestehen zunächst aus den Bewegungsgrößen des Fahrzeugs: Fahrgeschwindigkeit v , Längsbeschleunigung a_x und Querschleunigung a_y . In vielen Anwendungsfällen ist auch die benötigte Antriebsleistung von Interesse. Da Antriebstopologie und Systemzustände des Antriebs (z.B. Gangwahl) sowie weitere Einflussgrößen die vom Antrieb zu erbringende Leistung beeinflussen, verwendet man als Leistungsgröße meist die über die angetriebenen Räder abzugebende Radleistung P_R (vgl. (KF09, BRD⁺10, RBD⁺10, MFCS11, DBBK14)).

Unter Vernachlässigung von Fahrbahnquerneigung und Seitenwind, resultiert die Querschleunigung des Fahrzeugs ausschließlich aus den Seitenführungskräften des Fahrzeugs. Unter der Voraussetzung, dass die maximal möglichen Kräfte der Reifen dabei nicht überschritten werden, gilt für die Aufbauquerschleunigung dabei

$$a_y = \frac{v^2}{r} = v^2 \cdot \kappa \quad (3.1)$$

mit der Fahrzeuggeschwindigkeit v und dem Bahnradius r bzw. der Bahnkrümmung κ der Bewegung. Geht man vereinfacht davon aus, dass der Fahrer der Fahrspurmitte folgt, ist die Bahnkrümmung identisch mit der Straßenkrümmung. In diesem Fall ergibt sich die Querbeschleunigung somit direkt aus der Fahrzeuggeschwindigkeit und dem Straßenverlauf.

Unter Annahme bekannter Geschwindigkeit und Wunschbeschleunigung a_x des Fahrzeugs, berechnet sich die Radleistung P_R bei Vernachlässigung der Leistung durch Antriebs- oder Bremschlupf sowie Schräglaufwiderstand aus dem Fahrwiderstand F_W mit

$$P_R = F_W \cdot v = (F_L + F_S + F_R + F_B) \cdot v, \quad (3.2)$$

wobei sich F_W aus den Einzelkräften des Luftwiderstands F_L , des Steigungswiderstands F_S , des Radwiderstands F_R und des Beschleunigungswiderstands F_B zusammensetzt.

Dabei berechnet sich der Luftwiderstand F_L zu

$$F_L = \frac{1}{2} \rho_L \cdot c_W \cdot A \cdot v^2, \quad (3.3)$$

mit der Luftdichte ρ_L , dem Luftwiderstandsbeiwert c_W , der Fahrzeugfrontfläche A und der Fahrzeuggeschwindigkeit v .

Der Steigungswiderstands F_S ergibt sich mit der Fahrzeugmasse m , der Gravitationskonstante g und dem Steigungswinkel α zu

$$F_S = m \cdot g \cdot \sin \alpha. \quad (3.4)$$

Der Radwiderstand kann mit dem Radwiderstandsbeiwert f_R vereinfacht zu

$$F_R = f_R \cdot m \cdot g \cdot \cos \alpha \quad (3.5)$$

berechnet werden.

Der Beschleunigungswiderstand ergibt sich direkt aus der Längsbeschleunigung a_x zu

$$F_B = m' \cdot a_x, \quad (3.6)$$

wobei m' die Fahrzeugmasse mit Berücksichtigung der rotatorischen Masseanteile darstellt.

In Summe ergibt sich die Radleistung als eine Funktion von Fahrzeugparametern, der Fahrgeschwindigkeit, der Beschleunigung und der Fahrbahnsteigung:

$$P_R = F_W \cdot v = f(v, a_x, \alpha) \cdot v. \quad (3.7)$$

Die Radleistung kann während der Fahrt nicht direkt gemessen werden. Unter der Annahme, dass der Modellfehler zur Berechnung der Radleistung vernachlässigbar klein gegenüber Unsicherheiten einer Vorhersage ist, kann aber die Modellgröße der Radleistung nach Gl. (3.7) als Schätzung verwendet werden.

Die Radleistung P_R und Querbeschleunigung a_y ergeben sich somit als abhängige Größen von Geschwindigkeit v und Längsbeschleunigung a_x . Vorhersage von Geschwindigkeit bzw. Längsbeschleunigung ist folglich die zentrale Herausforderung in der Vorhersage der Fahrzeugdynamik.

Zur einfacheren Notation wird unter der Vorhersagevariablen y im Folgenden der Vektor der besagten Fahrzeugdynamikgrößen verstanden:

$$y = [v, a_x, a_y, P_R]^T. \quad (3.8)$$

3.2 Literaturüberblick Fahrermodellierung

3.2.1 Grundlagen der Fahrermodellierung

Die Vorhersage der Fahrzeugdynamik y ist untrennbar mit dem Fahrerverhalten verbunden. Das Thema Fahrerverhalten und -modellierung wird für zahlreiche Anwendungsgebiete aus unterschiedlichen Betrachtungsperspektiven behandelt. Im Folgenden werden die Modellierungsaspekte thematisiert, die aus Sicht einer Fahrzeugdynamikvorhersage notwendig sind. Weiterhin werden mathematische

⁴ Bei der Regelung des Fahrzeugs (z.B. Fahrerassistenzsystem) sind die hier bezeichneten Größen üblicherweise Systemzustände. Da in dieser Arbeit aber die Steuerung von Fahrzeugsystemen betrachtet wird und die Steuerung des Fahrzeugs dem Fahrer obliegt, handelt es sich aus Perspektive eines Fahrzeugsystems bei y im Allgemeinen um eine Umgebungsgröße bzw. Randbedingung.

Fahrermodelle, die im Zusammenhang mit Vorhersagen verwendet werden, analysiert. Ein Literaturüberblick zu Fahrermodellen mit unterschiedlichen Schwerpunkten findet sich unter anderem in (Ran94, Mac03, PE07, WH12, WXC14, KP15).

Hierarchisches Modell der Fahraufgabe

Ein sehr häufig referenziertes Modell zur Darstellung der Fahraufgabe ist das hierarchische 3-Ebenen-Modell (vgl. (Mic84)). Dieses Handlungs-Modell besteht aus drei Ebenen: Strategie-, Manöver- und Steuerungsebene.

Die strategische Ebene beschreibt die generelle Planungsebene einer Fahrt. Sie umfasst die eigentliche Ziel- und Routenplanung. Die Manöver-Ebene (auch taktische Ebene genannt) umfasst die Manöverplanung, also z.B. Spurwahl und -wechsel, Überholvorgänge und tolerierter Abstand zu anderen Fahrzeugen. Die daraus resultierende grobe Bahn- und Trajektorienplanung wird auf dieser Ebene gesteuert. Auf der untersten Ebene (Steuerungsebene) werden schließlich die eigentlichen Steuerhandlungen (Fahrpedal, Bremse, Lenkradwinkel, etc.) zur Erreichung der übergeordneten Ziele koordiniert.

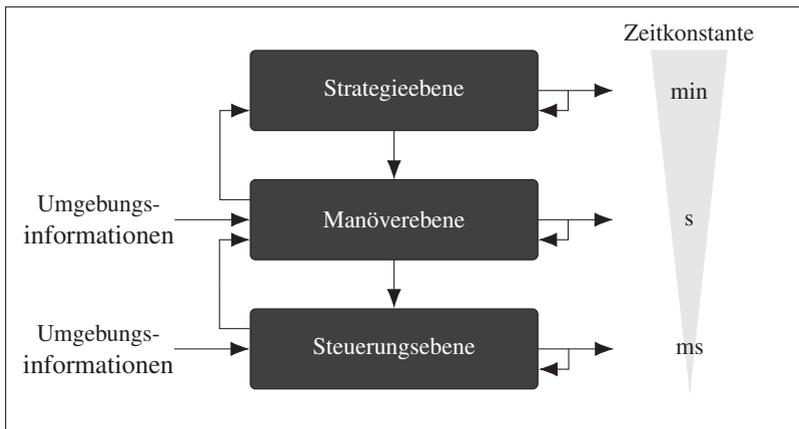


Abb. 3.1: Darstellung der Fahraufgabe nach (Mic84).

Die Vorhersage der Fahrzeugdynamik $y = [v, a_x, a_y, P_R]^T$ lässt sich im Wesentlichen der Manöverebene zuordnen, da die resultierende Geschwindigkeit und Beschleunigungen maßgeblich durch die grobe Bahn- und Trajektorienplanung dominiert wird. Regeltätigkeiten auf der Steuerungsebene wie Betätigung der Bremse und des Lenkrads üben zwar auch einen Einfluss auf die resultierende Fahrzeugdynamik aus, jedoch in geringerem Maße wie die Bahn- und Trajektorienplanung durch die Manöverebene. Die Strategieebene beeinflusst die resultierende Fahrzeugdynamik nur indirekt durch die übergeordnete Wahl der Route bzw. des Fahrtziels.

Fahrercharakterisierung und -klassifizierung

Während sich das zuvor geschilderte hierarchische Modell mit der prinzipiellen Darstellung der Fahraufgabe und involvierten Handlungsebenen widmet, wird häufig auch die Charakterisierung und Klassifizierung von unterschiedlichen Fahrertypen diskutiert.

Taubman-Ben-Ari et al. (TBAMG04) verweisen auf folgende, häufig unterschiedenen Fahrertypen:

- rücksichtslos und leichtsinnig
- ängstlich
- aggressiv und feindselig
- geduldig und vorsichtig

Diese psychologisch orientierte Klassifizierung wird vor allem im Zusammenhang mit Untersuchungen zur Sicherheit und Unfallprävention verwendet (siehe z.B. (TBAMG04)). Eine andere häufig eingesetzte Klassifizierung orientiert sich eher an fahrdynamischen Merkmalen (vgl. (Ebe06, BZKHK11, WL11, DGG14)). In solchen fahrdynamischen Klassifizierungen kommen meist folgende Fahrertypen in unterschiedlichen Abstufungen vor:

- sportlich
- normal
- entspannt

Als Merkmale der Fahrertypen werden dabei im Wesentlichen die gewünschte bzw. tolerierte Längs- und Querdynamik verwendet.

Da es keine allgemein akzeptierte Definition und Interpretation von Fahrstilen und dementsprechenden Klassifizierungen gibt, werden auch zahlreiche andere Fahrerklassifizierungen eingesetzt (z.B. im Zusammenhang mit Folgefahrt und Abstandsregelverhalten). In gleicher Weise existieren ebenso zahlreiche Methoden zur Ermittlung des Fahrstils aus Messdaten. Siehe hierzu (BNKZ11, DGG14, VLZ14, MG15).

Akzeptierte Querdynamik: Die Untersuchungen der Zusammenhänge zwischen Fahrzeugdynamikmerkmalen und dem Fahrertyp bzw. Fahrerverhalten wird in der Literatur schon seit geraumer Zeit thematisiert. Der Zusammenhang zwischen akzeptierter Querdynamik und Fahrgeschwindigkeit bzw. Fahrertyp wird z.B. in (Sch82, KD83, Man85, Sch85, Fuc93, vG96, Ham99, RKDB01, NH03, BZKHK11) diskutiert. Übereinstimmend wird meist ein allgemeiner Zusammenhang zwischen der akzeptierten Querbeschleunigung und dem individuellen Fahrstil berichtet. Weitere Abhängigkeiten oder typische Grenzwerte werden unterschiedlich wiedergegeben. Dies ist nicht zuletzt auf die teilweise sehr unterschiedlichen Zeiträume der Untersuchungen (Baujahr der Fahrzeuge) und die Rahmenbedingungen (Art der Fahrzeuge, Versuchsdurchführung, Versuchsumgebung oder Testpersonen) zurückzuführen. Meist bleiben jedoch auch andere Einflussfaktoren, wie z.B. Verordnungen und Bemessungsgrundlagen im Straßenwesen und damit einhergehende Randbedingungen, unberücksichtigt. Ein interessante Kenngröße, die in einigen Arbeiten thematisiert wird ((GMB84, vG96, RKDB01)) ist die *time to line crossing* (TLC). Die TLC beschreibt die zeitliche Sicherheitsreserve, die dem Fahrer bleibt, um auf einen Fehler im Lenkwinkel zu reagieren, ohne die Fahrbahnbegrenzungen zu überschreiten. Die TLC beschreibt damit zum einen den Zusammenhang der Geschwindigkeit über den Kurvenradius. Dabei ergibt sich für eine konstante TLC ein annähernd konstanter Zusammenhang zwischen Fahrgeschwindigkeit⁵ und akzeptierter Querbeschleunigung (RKDB01). Zum anderen beschreibt eine konstante TLC auch die Abhängigkeit der akzeptierten Geschwindigkeit bzw. Querbeschleunigung von der Breite der Straße und den Fähigkeiten des Fahrers. Sowohl bei geringerer Straßenbreite, als auch bei einer schlechteren Fähigkeit des Fahrers den Lenkwinkel zu schätzen und einzustellen, muss die Geschwindigkeit verringert werden, um eine konstante zeitliche Sicherheitsreserve im Sinne einer TLC beizubehalten. Nickel und Hugemann haben

⁵ Ausgenommen davon sind sehr geringe Geschwindigkeiten.

eine Studie mit unterschiedlichen Versuchsfahrern durchgeführt und die Längs- und Querschleunigungen im Alltagsverkehr aufgezeichnet (NH03). Der von ihnen berichtete Zusammenhang zwischen akzeptierter Querschleunigung und Kurvenradius zeigt eine ähnliche Charakteristik wie der Verlauf für eine konstante TLC.

Längsdynamik: Weitere Untersuchungen zeigen, dass sich Fahrer in ihrem Beschleunigungs- und Verzögerungsverhalten unterscheiden, wobei die Höhe der absoluten Beschleunigung charakteristisch für den Fahrstil ist (siehe z.B. (Fuc93, BZKHK11)). Zusätzlich zur Fahrerabhängigkeit, zeigen Untersuchungen weitere Abhängigkeiten wie z.B. von der zu überbrückenden Geschwindigkeitsdifferenz (KD83) oder dem Fahrzeugtyp (Fuc93). Ebenso zeigt sich eine generelle Abhängigkeit von der Geschwindigkeit, da die für die Beschleunigung benötigte Leistung mit der Geschwindigkeit ansteigt (BZKHK11).

Diese Abhängigkeiten stellen eine Herausforderung für die Abbildung von Fahrerverhalten dar. Dabei sind verschiedene Aspekte zu beachten. Ein komplexes Modell ermöglicht viele Freiheitsgrade in der Abbildungsfähigkeit, erschwert aber die Adaption und Identifikation der jeweiligen fahrerindividuellen Parameter im Fahrbetrieb. Eine größere Anzahl von berücksichtigten Parametern erlaubt so eine flexible Anpassung des Modells an gemessene Daten. Diese Flexibilität führt aber zu Einbußen in der Validität des Modells als Prädiktor (WH12). Winter et al. (WH12) weisen daher darauf hin, dass komplexere Fahrermodelle für Vorhersagemodelle nicht zielführend sind. Die tatsächlich gemessenen fahrdynamischen Größen sind das Resultat des Zusammenwirkens von äußeren Faktoren und den internen Handlungsprozessen des Fahrers auf der Manöver- und Steuerungsebene. Darüber hinaus ist zu berücksichtigen, dass der Fahrer kein technisches Regelsystem ist und die Regelgrößen nur mit einer gewissen Genauigkeit über kombinierte Sinneseindrücke ermitteln kann (Mac03).

3.2.2 Vorhersagemodelle

Im vorhergehenden Abschnitt wurden die allgemeinen Modellierungsaspekte für Fahrerverhalten thematisiert. In diesem Abschnitt werden in der Literatur eingesetzte Modelle zur Vorhersage von Fahrerverhalten oder resultierenden

Größen, wie der Fahrzeugdynamik behandelt. Dabei lassen sich vor allem Zeitreihen- und streckenbezogene Modelle unterscheiden.

Zeitreihen und zeitreihen-ähnliche Modelle

Zeitreihenmodelle sind Vorhersagemodelle der Form

$$\hat{y}_{t+1} = f(y_t, y_{t-1}, y_{t-2}, \dots) \quad (3.9)$$

(siehe hierzu auch Abschnitt 2.3.1).

Wie bereits in Abschnitt 2.1.2 erwähnt, werden sehr häufig Markov-Ketten als Zeitreihenmodelle für Fahrzeugdynamikgrößen verwendet. Markov-Ketten sind ein stochastisches Prozessmodell mit einem diskreten, endlichen Zustandsraum $\mathcal{S} = \{1, \dots, m\}$. Der zeitabhängige Zustand S_t der Markov-Kette wird dabei als Zufallsvariable modelliert mit $S_t \in \mathcal{S}$. Der nächste Zustand der Kette wird über die Matrix M der Übergangswahrscheinlichkeiten $P(S_{t+1}|S_t)$ definiert. Die Übergangsmatrix M beschreibt damit die Wahrscheinlichkeiten der Zustandswechsel über die bedingten Übergangswahrscheinlichkeiten $P(S_{t+1}|S_t)$ mit:

$$M = \begin{bmatrix} P(S_{t+1} = 1|S_t = 1) & \cdots & P(S_{t+1} = m|S_t = 1) \\ \vdots & \ddots & \vdots \\ P(S_{t+1} = 1|S_t = m) & \cdots & P(S_{t+1} = m|S_t = m) \end{bmatrix}. \quad (3.10)$$

Zur einfacheren Darstellung wird die Wahrscheinlichkeit $P(S_{t+1} = j|S_t = i)$ im Folgenden als p_{ij} bezeichnet. Abb. 3.2(a) veranschaulicht die Übergangsmöglichkeiten einer Markov-Kette mit drei Zuständen, Abb. 3.2(b) die mögliche Entwicklung des Zustands S_t über der Zeit.

In (DBBK14) wird z.B. eine Anwendung der Markov-Ketten zur Radleistungsvorhersage vorgestellt. Hierfür wird der auftretende Bereich der Radleistung in m Abschnitte entsprechend m Markov-Zuständen aufgeteilt. Die Übergangswahrscheinlichkeiten M werden aus Fahrzyklen ermittelt. Mithilfe des aktuellen Zustands S_t und der Übergangsmatrix M kann eine stochastische Vorhersage für die auftretende Radleistung berechnet werden. Vorteil der Markov-Ketten ist die relativ einfache Anwendbarkeit und der diskrete Zustandsraum, der sich

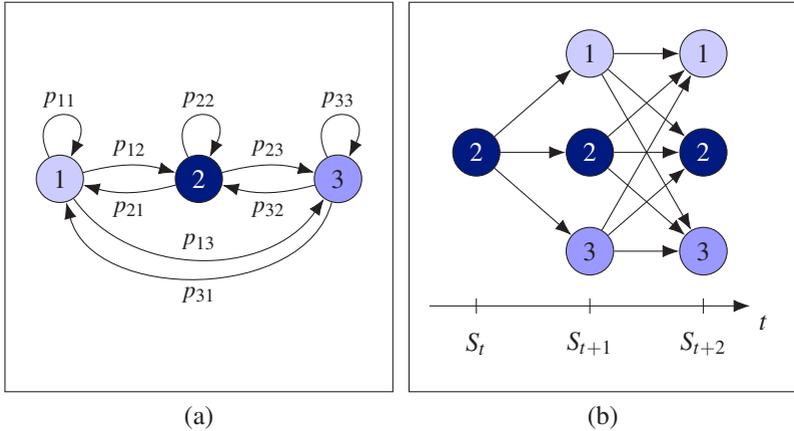


Abb. 3.2: Markov-Kette mit drei Zuständen und den Übergangswahrscheinlichkeiten p_{ij} in stationärer Darstellung (a) und Darstellung der zeitabhängigen Entwicklung vom Zustand $S_t = 2$ (b).

gut für eine numerische Weiterverarbeitung eignet. Offensichtlich ist die Vorhersage aber stark abhängig von den Trainingsdaten des Modells. Diese Form der Vorhersagen eignen sich daher vor allem zur Abbildung charakteristischer Eigenschaften eines typischen Fahrprofils, wie z.B. des täglichen Arbeitswegs. Ändern sich die Umgebungsbedingungen, also beispielsweise in Form eines nicht in den Trainingsdaten enthaltenen Streckenprofils, ist mit einer Abnahme der Vorhersagegüte zu rechnen.

Neben reinen Zeitreihenmodellen finden sich im automobilen Kontext häufig Mischformen des Typs

$$\hat{y}_{t+1} = f(y_t, y_{t-1}, \dots, e_t, e_{t-1}, \dots) \quad (3.11)$$

(siehe auch Abb. 2.4). Im Zusammenhang mit Folgefahrt-Verhalten werden beispielsweise PWARX⁶ eingesetzt (ASHI08). Die Idee hinter dem Einsatz solcher Modelle ist, dass sich das Verhalten durch die Kombination mehrerer einfacher (z.B. linearer) Modelle abbilden lässt. Solche Modelle werden

⁶ piecewise affine autoregressive models with exogenous input

häufig für Abbildung von Fahrerverhalten auf der Regelungsebene verwendet. In (ASHI08) wird ein solches Modell zur Vorhersage der Pedalansteuerung (Brems- und Fahrpedal-Stellung) eingesetzt. Als Eingangsgrößen dienen dabei der Abstand zum Vorderfahrzeug sowie dessen Zeitableitung. In (AMT12) wird ein Vergleich der Prädiktionsgüte zwischen einem PWARX-basiertem Ansatz (ähnlich des Modells in (ASHI08)) und einem auf Gaussian Mixture Models (GMM) basierenden Ansatz für die Pedalansteuerung in Folgefahrt durchgeführt. Die GMM-Variante bildet ein Wahrscheinlichkeitsmodell der Vorhersagegröße abhängig von den Eingangsgrößen ab. Dabei wird die Wahrscheinlichkeitsdichte für die nächste Pedalansteuerung über GMM abgebildet. Die Vorhersagegüte von GMM- und PWARX-basiertem Ansatz erweist sich nach (AMT12) als vergleichbar. Der ausgewertete Vorhersagehorizont liegt dabei zwischen einer und vier Sekunden.

Im Unterschied zu den Markov-Ketten, die auf eine Abbildung der charakteristischen Muster der Fahrzeugdynamikgrößen abhängig von Fahrer und Strecke abzielen, steht bei diesen Arbeiten die Abbildung menschlichen Regelverhaltens im Fokus (Regelungs-Ebene im hierarchischen Modell, siehe Abschnitt 3.2.1). Da außer den aktuellen Randbedingungen keine weiteren Informationen berücksichtigt werden, eignen sich solche Vorhersagemodelle nur für sehr kurze Zeithorizonte innerhalb des aktuellen Manövers.

Ein interessanter Ansatz zur Fahrsituationsvorhersage über ein Manöver hinaus findet sich in (TNH⁺15). Hierbei wird eine sprach-ähnliche Struktur zur Modellierung von Fahrverhalten und Fahrsituationen eingesetzt (als *double articulation analyzer* bezeichnet). Buchstaben repräsentieren dabei eine tatsächliche physikalische Messgröße, wie z.B. der Bremspedalweg oder Lenkradwinkel. Wörter repräsentieren situative Zustände, wie „rechts Abbiegen“ oder „geradeaus Fahren“. Durch Lernen einer Sprachlogik bzw. Grammatik (ähnlich des Satzbaus in der Sprache) kann dieses Modell zur Vorhersage der wahrscheinlichsten nächsten Situation eingesetzt werden. Der Ansatz von (TNH⁺15) verknüpft somit die Identifikation von Manövern mit logischen Manöverfolgen.

Streckenbezogene Modelle

Die bisher angeführten Verfahren modellieren die Vorhersage basierend auf dem vergangenen Verhalten der Vorhersagegröße selbst und dem vergangenen Verhalten anderer zusätzlicher Eingangsvariablen. Der Vorteil ist somit die universelle Einsetzbarkeit der Modelle, da keine externen Informationen benötigt werden. Dazu abgrenzen lassen sich Verfahren, die Streckeninformationen zur Vorhersage nutzen. Diese Art von Vorhersagen können als ein erklärendes Modell verstanden werden, das Informationen über zukünftige Randbedingungen verwendet (siehe auch Abb. 2.5). Diese Verfahren lassen sich nach der Art der Informationsbeschaffung in historien- und kartendatenbasierte Modelle unterscheiden.

Eine **historienbasierte** Vorhersagemethode für die Geschwindigkeit wird in (Mau11) vorgestellt. Grundlage des Verfahrens ist die Aufzeichnung von Geschwindigkeiten verknüpft mit GPS-Koordinaten. An den Stützstellen der GPS-Koordinaten wird mittels Kerndichteschätzung eine Verteilung der auftretenden Geschwindigkeiten ermittelt. Vorteil des Verfahrens ist die prinzipielle Berücksichtigung der auftretenden Streuung an einer Koordinate. Dem gegenüber steht der große Speicherbedarf bei lokaler Verarbeitung im Fahrzeug und die prinzipbedingte Abhängigkeit von bereits gefahrenen Strecken, um eine Geschwindigkeitsvorausschau bereitstellen zu können. Durch die mittlerweile vorhandene Konnektivität der Fahrzeuge kann die lokale Ermittlung der Geschwindigkeiten durch eine flottengestützte Geschwindigkeitsverteilung aus hochaufgelösten Verkehrsdaten ersetzt werden. Bei bekanntem Ziel lassen sich mit Verkehrsdaten Prognosen der Geschwindigkeit über einen langen Zeithorizont erstellen. Die Nutzung der Verkehrsdaten zur Geschwindigkeitsvorhersage wird z.B. in (GLP08, Wah15) behandelt. Bei ausreichender Abdeckung durch den Verkehrsdatenprovider können solche Verfahren ohne die Notwendigkeit von Trainingsdaten eingesetzt werden. Verkehrsdaten lassen sich nur zur Vorhersage der Geschwindigkeit jedoch nur schwer für die übrigen Vorhersagegrößen der Fahrzeugdynamik (z.B. Querbeschleunigung a_y und Radleistung P_R) einsetzen. Des Weiteren eignen sich Verkehrsdaten nur für die Bereitstellung gemittelter Größen über viele Verkehrsteilnehmer und ermöglichen keine situative oder fahrerindividuelle Adaption.

Kartendatenbasierte Vorhersagen nutzen sog. prädiktive Streckendaten als Informationsquelle. Prädiktive Streckendaten werden vom Navigationssystem

bereitgestellt und enthalten neben geometrischen Informationen des Straßenverlaufs (Krümmung und Steigung) auch Informationen wie beispielsweise gesetzliche Geschwindigkeitsbeschränkungen. Eine genauere Beschreibung der prädiktiven Streckendaten findet sich in Abschnitt 3.3. In (MRP04), (THP⁺10) und (FHFG16) finden sich Ansätze zur Geschwindigkeitsvorhersage mit Streckendaten. In allen der drei Arbeiten wird die Längsdynamik des Fahrers parametrisiert um Geschwindigkeitsübergänge zwischen Geschwindigkeitslimits zu berechnen. Die resultierende Vorhersage ist ein kontinuierlicher Geschwindigkeitsverlauf. In (THP⁺10) und (FHFG16) wird zusätzlich die aus dem Geschwindigkeitsverlauf resultierende Radleistung mittels eines Fahrzeugmodells ermittelt. Eine Untersuchung und Bewertung der Vorhersagegüte der Modelle findet in beiden Fällen nicht statt.

Cassebaum (Cas13) vergleicht das vorausschauende Energiemanagement eines Hybridfahrzeugs unter Verwendung eines historienbasierten und eines streckendatenbasierten Modells. Bei dem streckendatenbasierten Ansatz wird ähnlich wie in (MRP04) und (THP⁺10) die Längsdynamik des Fahrers parametrisiert. Zusätzlich erfolgt eine Berücksichtigung von Geschwindigkeitsverringerungen durch die Kurvigkeit der Strecke. Es ist zu beachten, dass die Parametrierung des Fahrers bei der späteren Anwendung der Vorhersage als bereits bekannt betrachtet wird. Für den historienbasierten Ansatz werden mehrere Messfahrten auf der gleichen Strecke durchgeführt. Aus dieser Trajektorienmenge wird mittels unterschiedlicher Verfahren (z.B. arithmetischer und geometrischer Mittelwert) eine positionsgestützte Geschwindigkeitsprognose abgeleitet. Die aufgezeichneten Messdaten zeigen eine deutliche Streuung der Geschwindigkeiten über unterschiedliche Fahrten. Die resultierende Energiemanagementstrategie unter Verwendung beider Prädiktionsansätze wird jeweils mit dem Resultat bei Idealprädiktion (Geschwindigkeitsprofil ist bekannt) verglichen. Cassebaum erzielt mit beiden Ansätzen vergleichbare Ergebnisse (Cas13). Im Mittel werden 0,8% bzw. 1% Verbrauchseinsparung erzielt. Zu beachten ist die deutliche Differenz zur Verbrauchseinsparung bei idealer Vorhersage (3%). In manchen Szenarien (Stadtfahrten) kommt es auch zu einer Verschlechterung des Verbrauchs durch den Einsatz der vorausschauenden Strategie. Dieses Beispiel verdeutlicht die Notwendigkeit der Betrachtung von Unsicherheiten bzw. Fehlern einer Vorhersage beim Einsatz von vorausschauenden Regelungsverfahren.

Fazit

Streckenbezogene Vorhersagen werden vor allem für die Fahrgeschwindigkeit verwendet. Dabei werden historienbasierte Ansätze sowie Verkehrsdaten und prädiktive Streckendaten eingesetzt. Während die Vorhersagen mit Verkehrsdaten vor allem auf mittleren Verkehrsgeschwindigkeiten beruhen, werden bei den bekannten Ansätzen mit prädiktiven Streckendaten auf Trajektorienmodellen basierende Vorhersagen verwendet. Verkehrsdaten können dabei für Prognosen mit langem Zeithorizont eingesetzt werden, während die Trajektorienmodelle sich eher für einen kürzeren Zeithorizont eignen.

Werden die Vorhersagen ohne Informationen über die voraus liegende Strecke berechnet, kommen vor allem für die Regelungsebene der Fahraufgabe parametrische und nicht-parameterische Vorhersagemodelle zum Einsatz (kurze Vorhersage-Zeithorizonte). Anwendungsgebiete sind dabei vor allem im Bereich von Folgefahrt- und Abstandsregelverhalten zu finden. Auf einem längeren Zeithorizont werden hauptsächlich stochastische Modellierungen mit Markov-Ketten für Vorhersagen fahrdynamischer Größen eingesetzt. Diese Form der Modellierung eignet sich dabei zur Abbildung genereller Fahrer-Strecke-Charakteristika, bildet aber keine situationsspezifischen Informationen ab.

Grundsätzlich verspricht die Verwendung prädiktiver Streckendaten eine hohe Validität der Vorhersagen für die relevanten Fahrzeugdynamikgrößen. Dabei wurde in den bisherigen Ansätzen dieser Kategorie die Unsicherheit von solchen Vorhersagen vernachlässigt. Ebenso befassen sich nur wenige Arbeiten mit der generellen Bewertung und Validierung der Vorhersagemodelle. Dass die Vernachlässigung von Unsicherheiten von Vorhersagen vor allem im Zusammenhang mit Optimalsteuerungsverfahren kritisch zu sehen ist, ist in der Literatur bekannt und wurde in Abschnitt 2.3 erläutert. Da die Vorhersage der Fahrzeugdynamik eine der zentralen Herausforderungen für neue Anwendungen im Bereich der vorausschauenden Regelung von Fahrzeugsystemen darstellt, soll die fahrerindividuelle und situationsspezifische Vorhersage der Fahrzeugdynamik unter Berücksichtigung von Unsicherheiten in den folgenden Abschnitten systematisch hergeleitet werden.

3.3 Prädiktive Streckendaten

Prädiktive Streckendaten (PSD) werden vor allem für *advanced driver assistance systems* (ADAS) eingesetzt und vom Navigationsgerät bereitgestellt. Die Daten werden dabei mittels eines Übertragungsprotokolls (z.B. ADASIS-v2 (RBB⁺08)) über den Fahrzeug-Kommunikationsbus versendet. Mittels der im Protokoll übertragenen Daten wird in Fahrtrichtung des Fahrzeugs ein elektronischer Horizont (EH) als Baumstruktur der vorausliegenden Streckensegmente aufgebaut. Dieser wird zyklisch aktualisiert und enthält unter anderem Attribute für Straßenklassen, Geschwindigkeitsbeschränkungen, Kurvenkrümmungen, Abbiegewinkel, Steigungen und Kreuzungsinformationen. Wenn keine Zielführung aktiv ist, orientiert sich der Aufbau des EH am wahrscheinlichsten Pfad (MPP - engl.: Most Probable Path), der vom Navigationsgerät typischerweise anhand statischer Regeln ermittelt wird. Ein beispielhafter elektronischer Horizont ist in Abb. 3.3 dargestellt.

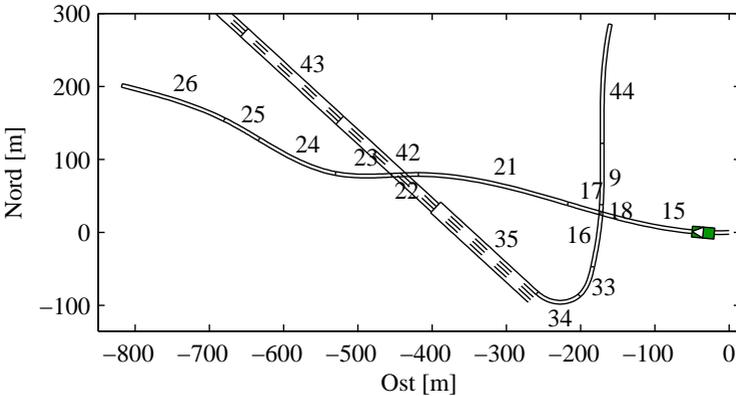


Abb. 3.3: Elektronischer Horizont der vorausliegenden Strecke. Die Segmente sind baumartig von der Position des Fahrzeugs aufgebaut und nummeriert (Positionsangaben relativ zum Startpunkt des Wurzelsegments - hier Nr. 15).

Der elektronische Horizont enthält somit sowohl eine geometrische Beschreibung der vorausliegenden Straße als auch zusätzliche Informationen wie gesetzliche Beschränkungen. Der EH hat typischerweise eine Länge von einigen

hundert bis wenigen tausend Metern, abhängig von der Verzweigkeit des Straßennetzes und dem Straßenverlauf.

3.4 Teststrecke und Messfahrten

Zur Untersuchung von Vorhersagemodellen und Verfahren zur vorausschauenden Steuerung wird ein Testset an Messfahrten benötigt. Da unterschiedliches Fahrerverhalten ein relevanter Faktor für die Fahrzeugdynamik ist, sollen diese Testdaten aus Aufzeichnungen mit unterschiedlichen Fahrern bestehen. Ebenso soll die verwendete Teststrecke charakteristische Elemente für fahrdynamisches relevantes Verhalten enthalten.

Die Teststrecke im Raum Stuttgart wurde so gewählt, dass sie sowohl kurvige Landstraßen, Ortschaften als auch Autobahnanteile enthält (siehe Abb. 3.4). Die Gesamtlänge der Strecke beläuft sich auf ca. 37.5 km. Die Teststrecke

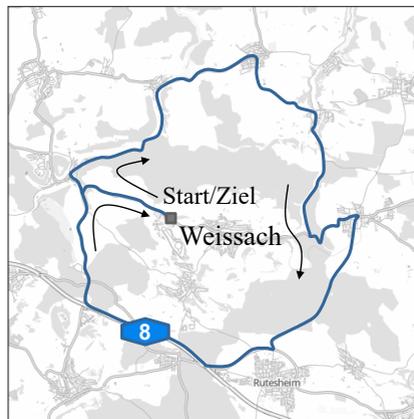


Abb. 3.4: Gewählte Strecke für die Testfahrten. Start und Ziel jeweils am Entwicklungszentrum Weissach. Zu Beginn bestehend aus einer Überlandstrecke mit einigen Ortsdurchfahrten und einem Abschnitt auf der Autobahn A8 gegen Ende der Strecke. ©OpenStreetMaps

wurde mit neun unterschiedlichen Fahrern aufgezeichnet. Es wurden dabei keine Instruktionen bezüglich des Fahrverhaltens gegeben. Für die Durchführung der

Messfahrten standen ein Porsche 911 Carrera 4S und ein Porsche Panamera Turbo zur Verfügung (Fahrzeugdaten siehe Tabelle 3.1). Drei der Fahrten wurden mit dem 911 Carrera 4S und sechs mit dem Panamera Turbo durchgeführt. Da die Fahrzeuge ein ähnliches Leistungsgewicht besitzen, sind nur geringe durch das Fahrzeug verursachten Unterschiede im längsdynamischen Fahrerverhalten zu erwarten.

Tabelle 3.1: Technische Daten der verwendeten Testfahrzeuge.

	Porsche 911 Carrera 4S Cabrio	Porsche Panamera Turbo
Leistung	294 kW (400 PS)	382 kW (520 PS)
Leergewicht*	1.555 kg - 1.635 kg	1.970 kg - 2.175 kg

* nach DIN 70020.

Abb. 3.5 zeigt die Geschwindigkeitsverläufe der Fahrten. Weitere Abbildungen zu den aufgezeichneten Fahrten finden sich in Anhang A.1.

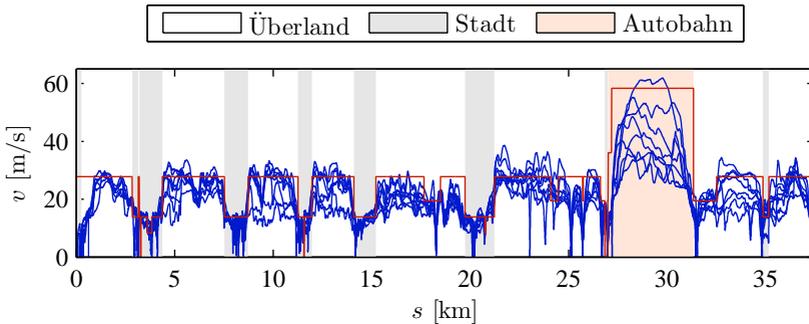


Abb. 3.5: Geschwindigkeit v über der Fahrtstrecke s für die aufgezeichneten Testfahrten.

3.5 Stochastisches Framework zur Fahrzeugdynamikvorhersage

Vorhersagen auf Basis von Streckendaten erfordern ein Trajektorienmodell, das den Zusammenhang zwischen den Streckendaten und den gesuchten Fahrzeugdynamikgrößen beschreibt. Während klassische zeitreihenbasierte Vorhersagemodelle (z.B. Markov-Ketten) durchgängig stochastisch formuliert sind, hat diese Unsicherheitsmodellierung bei der Verwendung von Streckendaten bisher wenig Beachtung gefunden und es wird ein deterministischer Zusammenhang vorausgesetzt. Dies ist aus mehreren Gründen problematisch.

Zum einen setzt ein deterministischer Zusammenhang deterministisches Verhalten (im Parameterraum des Trajektorienmodells) und somit meist auch eine Zeitinvarianz des Fahrerverhaltens voraus. Die Suche nach der richtigen Parametrierung des Trajektorienmodells und dem konkreten Parametersatz eines Fahrers wird somit zu einer sehr komplexen, wenn nicht unlösbaren Aufgabe. Dies kann als einer der Gründe für die von Winter und Happee (WH12) erwähnte typische Überparametrierung von Fahrermodellen im Zusammenhang mit Vorhersagen vermutet werden. Passt das vorgeschlagene Modell mit seinen adaptierten Parametern nicht zum beobachteten Verhalten des Fahrers, müssen zusätzliche Parameter hinzugefügt werden, um eine weitere Anpassung des Modells zu ermöglichen.

Zum anderen vernachlässigt die deterministische Formulierung eine Betrachtung von Unsicherheiten in der Vorhersage. So kann keine Kommunikation von beobachteten Unsicherheiten oder uneindeutigen Situationen erfolgen (Bsp.: Kreuzungen und Abbiegemöglichkeiten oder das Verhalten anderer Verkehrsteilnehmer). Der Nutzer der Vorhersage, in diesem Fall eine vorausschauende Regelung bzw. Optimalsteuerung, wird so in falscher Sicherheit gewogen und kann nicht angemessen auf die Situation reagieren. Die Frage ist somit, wie eine streckendatenbasierte Trajektorienvorhersage unter Berücksichtigung von Unsicherheiten erreicht werden kann.

Eine Möglichkeit hierfür ist die stochastische Formulierung im Parameterraum der Übertragungsfunktion (vgl. (FHFG17)). Solche Verfahrensweisen werden z.B. in der Manöर्वorhersage für die Risiko- und Situationsbewertung im Zusammenhang intelligenter Fahrzeuge eingesetzt (vgl. (LVL14)). Die zwei Grundbestandteile einer solchen Formulierung sind eine Träger- oder

Transferfunktion, die den grundsätzlichen Zusammenhang zwischen den Vorhersagegrößen und den Eingangsdaten parametrisiert und eine stochastische Modellierung im Parameterraum der Funktion, die wiederum unterschiedliche Verhaltensweisen innerhalb der Formulierung der Transferfunktion berücksichtigt. Eine solche Modellierung soll in diesem Abschnitt für die Vorhersage der Fahrzeugdynamik mit Streckendaten erarbeitet werden.

Abb. 3.6 zeigt diese Form der Vorhersage in einer schematischen Darstellung. Dabei sind folgende Arbeitsschritte notwendig:

- (1) Ableitung geeigneter Beobachtungsgrößen (ϑ , siehe Gleichung 3.26) aus dem Ist-Verlauf der Vorhersagegrößen (y , siehe Gleichung 3.8).
- (2) Inferenz der Prozessparameter (θ , siehe Gleichung 3.27) des stochastischen Modells (Γ), die das Verhalten beschreiben.
- (3) Ableitung zukünftiger Parameterwerte (γ) der Transferfunktion, basierend auf dem stochastischen Modell.
- (4) Vorhersage (\hat{y}) durch Übertragung der Parameterwerte in den Bildraum mit der Transferfunktion f_T .

In den nächsten Abschnitten werden zunächst die Modellierungsaspekte der Transferfunktion (5) und des stochastischen Modells (6) diskutiert.

3.5.1 Transferfunktion

Die Transferfunktion hat die Aufgabe, die grundlegenden Zusammenhänge zwischen den Streckendaten und der Fahrzeugdynamik zu beschreiben und zu parametrieren.

Parametrierung der Geschwindigkeit: Die Höchstgeschwindigkeit ist bei unbeeinflusster Fahrt zunächst durch die gesetzliche Geschwindigkeitsbeschränkung vorgegeben. Studien zu Fahrerverhalten zeigen, dass Fahrer die Geschwindigkeitsbeschränkung sowohl systematisch unter- als auch überschreiten (siehe z.B. (HA02, Roy03)). Diese Abweichung wird dabei von Umweltfaktoren wie der Straßenklasse, den Wetterbedingungen, Verkehrsfluss oder der sozialen Umgebung beeinflusst (Zai92). Grundsätzlich ist es also naheliegend die Zielgeschwindigkeit über das Geschwindigkeitslimit und eine Abweichung hierzu zu beschreiben. Die Zielgeschwindigkeit v_Z wird somit über das Geschwindigkeitslimit v_{lim} und ein Geschwindigkeitsoffset v_Δ (positiv oder negativ)

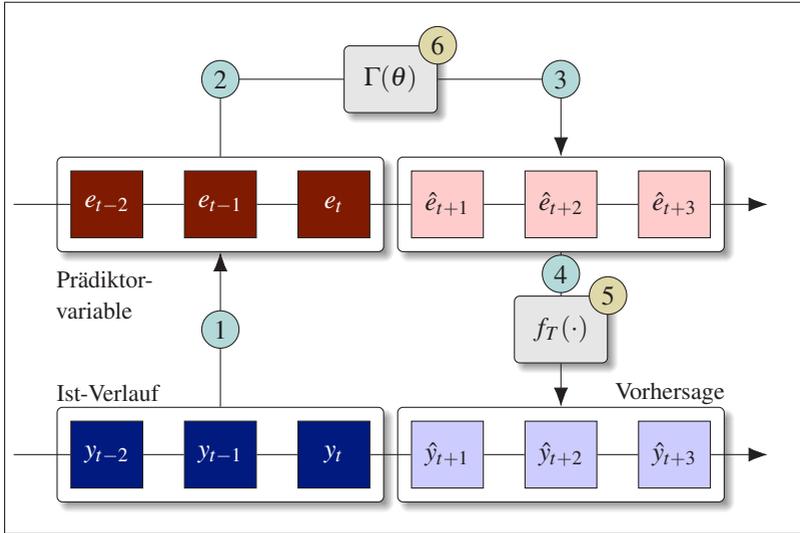


Abb. 3.6: Prinzip-Darstellung der Vorhersage für y mit einer Prädiktorvariablen e und einem stochastischen Modell $\Gamma(\theta)$ für die Vorhersage der Prädiktorvariable sowie einer Transferfunktion zur Ermittlung der eigentlichen Vorhersagevariable \hat{y} .

beschrieben. Im Sonderfall eines unbeschränkten Streckenabschnitts ist diese relative Parametrierung nicht möglich. Daher wird für unbeschränkte Strecken die Freifahrtgeschwindigkeit v_{max} als zusätzlicher Parameter definiert. Damit ist die Zielgeschwindigkeit v_Z durch

$$v_Z = \begin{cases} v_{max}, & \text{falls } \nexists v_{lim} \\ v_{lim} + v_{\Delta}, & \text{falls } \exists v_{lim} \end{cases} \quad (3.12)$$

definiert, wobei v_{lim} die aktuell gültige Geschwindigkeitsbeschränkung ist.

Parametrierung des dynamischen Verhaltens: Neben der Geschwindigkeit bei unbeeinflusster Fahrt ist eine Parametrierung für das dynamische Verhalten notwendig. Dazu zählen zum einen Übergänge zwischen Geschwindigkeitsbeschränkungen und zum anderen Einschränkungen durch Kurven und Abbiegungen. Die vielfältigen Abhängigkeiten des dynamischen Verhaltens (siehe Abschnitt 3.2.1) stellen eine Herausforderung für die Parametrierung dar. Gemäß

der Argumentation von WINTER UND HAPPEE (WH12) ist für Vorhersagen von Fahrerverhalten eine einfache Parametrierung anzustreben, da komplexe Modelle häufig eine schlechtere Eignung als Prädiktor aufweisen. Desweiteren ist zu berücksichtigen, dass nicht alle Größen, denen in der Literatur ein Einfluss zugesprochen wird, auch in den aktuellen Kartendaten verfügbar sind (z.B. Straßenbreite). Vereinfachend wird daher von konstanten Längsbeschleunigungs- und Längsverzögerungsgrenzen $a_{x,max}$ und $a_{x,min}$ ausgegangen. Ebenso wird für das Querdynamikverhalten zunächst eine geometrie- und geschwindigkeitsunabhängige maximal tolerierte Querbeschleunigung $a_{y,max}$ angenommen. Zusätzlich wird für die Längsbeschleunigung eine Radleistungsgrenze P_{max} definiert, um die Ausnutzung der vorhandenen Motorleistung durch den Fahrer zu parametrieren.

Um stetige Beschleunigungsverläufe und ruckfreie Geschwindigkeitsverläufe zu gewährleisten, wird die Änderungsrate der Beschleunigung (der Ruck) auf einen maximal zulässigen Betrag j_{max} begrenzt (vgl. (FHFG17)).

Zuletzt wird zur vollständigen Parametrierung der Transferfunktion noch das Zielsegment s_{ID} hinzugefügt, das die Route auf dem aktuellen Segmentbaum \mathcal{T}_{PSD} definiert. Der Parametervektor γ der Transferfunktion ist damit durch

$$\gamma = [v_{\Delta}, v_{max}, a_{x,max}, a_{x,min}, a_{y,max}, P_{max}, j_{max}, s_{ID}]^T \quad (3.13)$$

gegeben. Der zulässige Geschwindigkeitsraum wird durch die Zielgeschwindigkeit (v_{Δ} und v_{max}) sowie die maximal tolerierte Querbeschleunigung $a_{y,max}$ beschränkt. Die Geschwindigkeitsbeschränkung einer gekrümmten Strecke ergibt sich bei Annahme spurmittiger Fahrt zu

$$v_{Kurve} = \sqrt{a_{y,max} \cdot r} \quad (3.14)$$

mit Kurvenradius r . Die längsdynamischen Parameter ($a_{x,max}$, $a_{x,min}$, j_{max} , P_{max}) beeinflussen das Übergangsverhalten zwischen den einzelnen Geschwindigkeitsbeschränkungen.

Die Berechnung der Bewegungstrajektorie des Fahrzeugs und damit der Fahrzeugdynamik y erfolgt zeitdiskret. Die Transferfunktion f_T kann mit dem

aktuellen Zustand der Fahrzeugdynamik y_t und der Fahrzeugposition s_t damit als nichtlineare Funktion

$$y_{t+1} = \begin{bmatrix} v_{t+1} \\ a_{x,t+1} \\ a_{y,t+1} \\ P_{R,t+1} \end{bmatrix} = f_T(y_t, s_t, \gamma, \mathcal{T}_{PSD}) \quad (3.15)$$

geschrieben werden. Zur Integration der Bewegungsgrößen wird über einen Zeitschritt mit abschnittsweise konstantem Ruck⁷ und damit linearem Beschleunigungsverlauf gerechnet. Sei $a_{x,t+1}$ die zulässige Beschleunigung des nächsten Zeitschritts, dann gilt für die neue Fahrzeugposition:

$$s_{t+1} = s_t + v_t \Delta t + \left(\frac{a_{x,t}}{3} + \frac{a_{x,t+1}}{6} \right) \Delta t^2. \quad (3.16)$$

Die zeitdiskrete Auswertung der Transferfunktion f_T ist in Abschnitt A.2 genauer beschrieben.

Abb. 3.7 zeigt beispielhafte Verläufe der Vorhersagegröße y für zwei unterschiedliche Zielsegmente aus Abb. 3.3 mit den zugehörigen Parametervektoren

$$\gamma_1 = [0\text{m/s}, 36.11\text{m/s}, 3\text{m/s}^2, -3\text{m/s}^2, 4\text{m/s}^2, P_3^{100}\text{kW}, 1.5\text{m/s}^3, 26]^T,$$

sowie $\gamma_2 = \gamma_1$ mit Ausnahme des Zielsegments: Zielsegment $s_{ID} = 43$ (Autobahn) für γ_2 , im Gegensatz zu $s_{ID} = 26$ (Landstraße) bei γ_1 .⁸ $P_{a_x}^{100}$ bezeichnet hierbei die Radleistung, die für die Beschleunigung a_x (in m/s^2) bei 100 km/h benötigt wird. In Abb. 3.8 sind Verläufe der Vorhersagegröße für unterschiedlich Parametrierungen von γ visualisiert (Werte entsprechend Tab. 3.2 in Abschnitt 3.6.2).

⁷ Zeitableitung der Beschleunigung.

⁸ Mit festgelegten Parametern γ der Transferfunktion (Trajektorienmodell), kann für jede Position aus Kurvenkrümmungen und gesetzl. Geschwindigkeitslimitierungen eine obere Beschränkung für die Fahrzeuggeschwindigkeit ermittelt werden. Der Verlauf der Fahrzeuggeschwindigkeit kann dann unter Einhaltung der vorgegebenen Ruckbeschränkungen von diesen oberen Beschränkungen ausgehend errechnet werden.

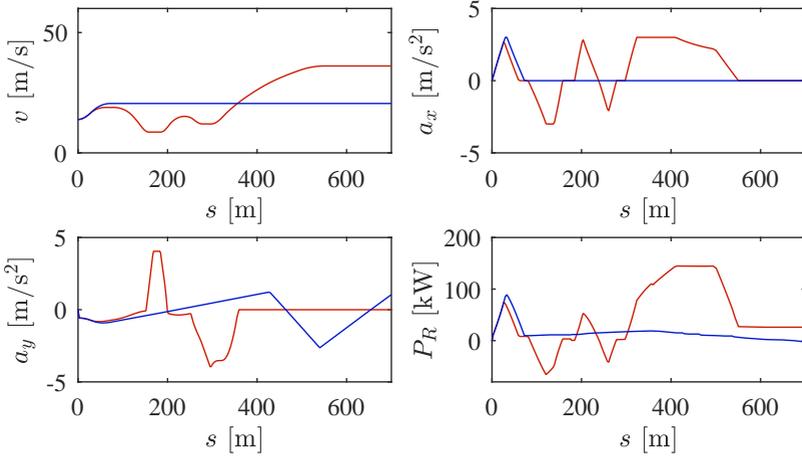


Abb. 3.7: Beispielhafte Trajektorien (Geschwindigkeit v , Längsbeschleunigung a_x , Querbeschleunigung a_y und Radleistung P_R) für unterschiedliche Zielsegmente der Situation aus Abb. 3.3 (Parametervektoren γ_1 (blau) und γ_2 (rot)).

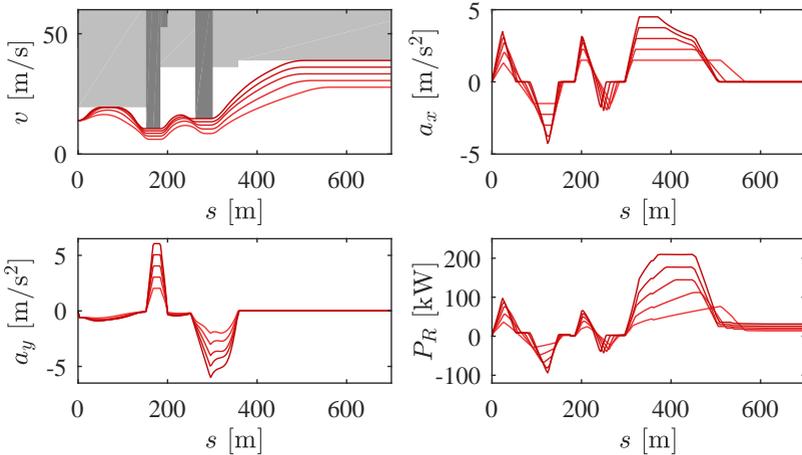


Abb. 3.8: Beispielhafte Trajektorien (Geschwindigkeit v , Längsbeschleunigung a_x , Querbeschleunigung a_y und Radleistung P_R) für die Autobahnroute aus Abb. 3.3 mit unterschiedlich parametrierter Fahrerwunschdynamik. Graue Flächen markieren Einschränkungen durch Geschwindigkeitslimits oder Kurven.

3.5.2 Stochastische Prozessmodellierung

Der zweite Bestandteil des Vorhersagemodells nach der Transferfunktion ist die Modellierung eines stochastischen Prozesses im Parameterraum der Transferfunktion, der die Unsicherheiten und Einflüsse berücksichtigt. Für die stochastische Modellierung müssen also die Einflüsse und deren Unsicherheiten analysiert und geeignete stochastische Beschreibungen hergeleitet werden.

Route

Für die Vorhersage muss zunächst das Fahrtziel, also die ID des Zielsegments s_{ID} auf dem aktuellen Segmentbaum bekannt sein. Für den Fall einer aktiven Routenführung durch das Navigationssystem ist dieses Zielsegment bekannt. In allen anderen Fällen muss das Zielsegment geschätzt werden und ist folglich mit einer Unsicherheit verbunden. Dies kann über die Zuweisung von Wahrscheinlichkeiten für die einzelnen Routenoptionen erfolgen.

Prinzipiell können zwei Verfahrensweisen zur Ermittlung der Routenwahrscheinlichkeiten unterschieden werden. Die Segmentwahrscheinlichkeiten können als **A-Posteriori-Wahrscheinlichkeiten** abgeleitet werden. In diesem Fall

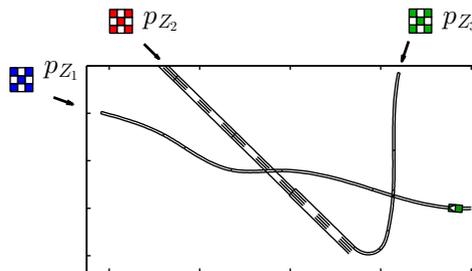


Abb. 3.9: Zuweisung der Segmentwahrscheinlichkeiten mittels A-Posteriori-Wahrscheinlichkeiten, ausgehend von möglichen Zielen außerhalb des elektronischen Horizonts. Die Wahrscheinlichkeit der Segmente an der Kreuzung ergeben sich aus den Wahrscheinlichkeiten der möglichen Ziele ($p_{Z_1}, p_{Z_2}, p_{Z_3}$) bzw. deren Pfadwahrscheinlichkeiten.

würden die Wahrscheinlichkeiten, ausgehend von möglichen „globalen“ Zielen - außerhalb des elektronischen Horizonts - ermittelt werden. Diese Ziele können zum Beispiel aus vergangenen Fahrten des Fahrers abgeleitet werden. Die Ermittlung möglicher Ziele bzw. Routen ist Gegenstand zahlreicher Arbeiten (siehe z.B. (CLY⁺11, FK08, KB03, LJEL12, SBS06)).

Davon unterscheiden lässt sich die Zuweisung von **A-Priori-Wahrscheinlichkeiten** für die Segmente. In diesem Fall werden die Wahrscheinlichkeiten ohne Vorkenntnisse aus dem Segmentbaum abgeleitet. Da die Routenermittlung und -identifikation nicht im Fokus dieser Arbeit liegt, wird folgend ein a priori Verfahren zur Festlegung der Segmentwahrscheinlichkeiten beschrieben und im Weiteren verwendet.

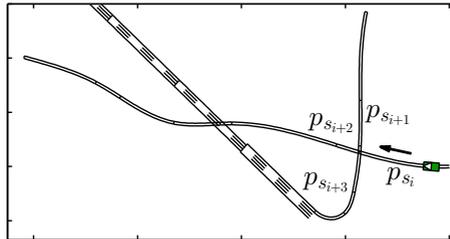


Abb. 3.10: Zuweisung der Segmentwahrscheinlichkeiten mittels A-Priori-Wahrscheinlichkeiten, ausgehend von der Fahrzeugposition. Die Wahrscheinlichkeit der Segmente an der Kreuzung wird direkt bestimmt/vorgegeben. Die Wahrscheinlichkeiten für einzelne Pfade/Ziele ergeben sich aus der Kombination der Wahrscheinlichkeiten aller dazugehörigen Segmente.

Zuweisung von Segmentwahrscheinlichkeiten: Bei unbekannter Route oder inaktiver Zielführung gilt: Sei $\{s_{i+1}, \dots, s_{i+N}\}$ die Menge aller vom Segment

s_i abzweigender Segmente, dann werden die Segmentwahrscheinlichkeiten p_{s_j} mit

$$p_{s_j} = \frac{w_j}{\sum_{k=i+1}^N w_k}, \forall j \in [i+1, i+N],$$

$$w_k = \begin{cases} \varepsilon_1 & \text{falls } s_k \in \mathcal{S}_{MPP} \\ \varepsilon_2 & \text{falls } \alpha(s_k) = 0 \\ \varepsilon_1 + \varepsilon_2 & \text{falls } s_k \in \mathcal{S}_{MPP} \wedge \alpha(s_k) = 0 \\ 1 & \text{sonst} \end{cases}, \varepsilon_1 \geq 1, \varepsilon_2 \geq 1 \quad (3.17)$$

berechnet. Dabei ist \mathcal{S}_{MPP} die Menge aller Segmente des Most Probable Path (siehe Abschnitt 3.3) und $\alpha(s_k)$ der Abbiegewinkel des Segments s_k . Dadurch werden die Gewichtungen von Segmenten des MPP bzw. von Segmenten ohne Abbiegewinkel um ε_1 bzw. ε_2 erhöht.

Bei bekannter Route oder aktiver Zielführung gilt (der MPP entspricht in diesem Fall der Route der Zielführung):

$$p_{s_j} = \frac{w_j}{\sum_{k=i+1}^N w_k}, \forall j \in [i+1, i+N],$$

$$w_k = \begin{cases} 1 & \text{falls } s_k \in \mathcal{S}_{MPP} \\ 0 & \text{sonst} \end{cases}. \quad (3.18)$$

Im Folgenden wird der stochastische Prozess, der mögliche Zielsegmente s_i entsprechend der Segmentwahrscheinlichkeit p_{s_i} zuweist, mit Γ_r bezeichnet.

Zielgeschwindigkeit

Wie im Abschnitt 3.5.1 erläutert, wird die Zielgeschwindigkeit durch das Geschwindigkeitsoffset v_Δ und die Maximalgeschwindigkeit v_{max} beschrieben. Diese Parameter bilden das Geschwindigkeitsverhalten ohne querdynamische Einschränkungen (Kurven und Abbiegungen) ab. Dieses Verhalten unterliegt dabei vielfältigen Einflüssen (vgl. (Zai92, HA02)) und ist nicht als konstant anzunehmen (HA02). Es wird daher von einer Zufallsverteilung V_Δ des Parameters v_Δ ausgegangen. Es ist dabei zu beachten, dass v_Z bzw. v_Δ nicht direkt beobachtet werden kann (siehe hierzu auch Abschnitt 3.6). Dies ist darin be-

gründet, dass die beobachtbare Geschwindigkeit v Produkt aller statischen und dynamischen Einschränkungen ist, wohingegen v_Z ein Parameter der zugrundeliegenden Transferfunktion f_T ist. Für das Geschwindigkeitsoffset und die Maximalgeschwindigkeit wird dabei eine Gaußverteilung $V_\Delta = \mathcal{N}(\mu_\Delta, \sigma_\Delta^2)$ bzw. $V_{max} = \mathcal{N}(\mu_{max}, \sigma_{max}^2)$ angenommen. Für v_Z gilt somit die kombinierte Verteilungsfunktion V_Z mit

$$v_Z \sim V_Z = \begin{cases} V_{max}, & \text{falls } \nexists v_{lim} \\ v_{lim} + V_\Delta, & \text{sonst} \end{cases} . \quad (3.19)$$

Neben der absoluten Beschreibung V_Z , wird eine Beschreibung für das zeitliche Verhalten ohne Änderung der Geschwindigkeitsbeschränkung benötigt. Dieses zeitliche Verhalten kann als Drift bzw. zufälliges Schwanken der Zielgeschwindigkeit beschrieben werden, verursacht z.B. durch das Blick- und Regelverhalten des Fahrers (ZW13) oder andere Störeinflüsse wie Verkehr oder veränderte Umgebungsbedingungen (Bebauung, Straßenbeschaffenheit, o.ä.). Abb. (3.11) zeigt beispielhafte Geschwindigkeitsverläufe bei Testfahrten unterschiedlicher Fahrer auf einem Landstraßen- (a) und einem Autobahnabschnitt (b). In beiden Fällen ist das Geschwindigkeitslimit konstant und es sind keine relevanten Einschränkungen durch Kurven vorhanden. Die Kurveneinschränkung wird durch die Begrenzung für $|a_y| \leq 2\text{m/s}^2$ visualisiert, was der Querbeschleunigungsgrenze eines ruhigen Fahrers nach Hamberger (Ham99) entspricht.

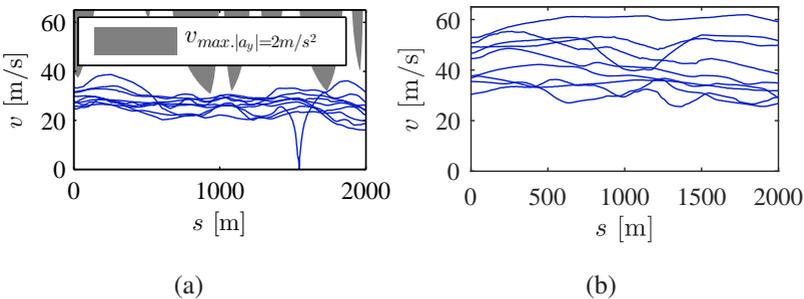


Abb. 3.11: Beispielhafte Geschwindigkeitsverläufe v über Strecke s für einen Landstraßen- (a) und Autobahnabschnitt (b) aus den Testfahrten. Die graue Markierung zeigt Einschränkungen durch Kurven bei einer tolerierten Querbeschleunigung von 2 m/s^2 .

Da für die Modellierung dieses Zeitverhaltens kein durchgängiges Erklärungsmodell möglich scheint, soll dieses Verhalten über eine Zeitreihenmodellierung beschrieben werden. Autoregressive Prozesse werden häufig zur Beschreibung von wert-kontinuierlichen Zeitreihen eingesetzt (vgl. (SS11, Mud14)) und kommen für diese Modellierung in Frage.

Ein autoregressiver Prozess (AR) beschreibt eine Zeitreihe, bei der sich der aktuelle Wert der Zeitreihe aus einer Linearkombination der p vorhergehenden Werte und einem zufälligen Rauschterm zusammensetzt. Diese Prozesse sind somit geeignet die zeitliche Korrelation einer Zeitreihe zu beschreiben. Ein autoregressiver Prozess von Ordnung p (AR(p)) ist dabei mit

$$y_t = c + \varepsilon_t + \sum_{i=1}^p \phi \cdot y_{t-i}, \quad (3.20)$$

durch die Kombination einer Konstanten c , eines Rauschterms ε_t und eines gewichteten, gleitenden Mittels der p vorhergehenden Werte der Zeitreihe definiert. Für den Rauschterm wird üblicherweise eine unabhängige, identische Gaußverteilung mit Erwartungswert null angenommen. Unter Vernachlässigung von Saisonalität wird im Folgenden der AR(1)-Prozess

$$y_t = c + \varepsilon_t + \phi \cdot y_{t-1}, \quad \varepsilon_t \propto \mathcal{N}(0, \sigma_\varepsilon^2) \quad (3.21)$$

betrachtet. Für $c = 0$ und den Grenzfall $\phi = 0$ entspricht der Prozess weißem Rauschen, während man für $\phi = 1$ von einem Random Walk spricht. Für $0 < \phi < 1$ beschreibt das Modell einen Zufallsprozess mit Korrelation aufeinanderfolgender Realisierungen und einer Gauß-verteilten Innovation ε_t . Der AR(1) Prozess ist stationär für $|\phi| < 1$ und hat den Erwartungswert

$$\mathbb{E}(y_t) = \frac{c}{1 - \phi}. \quad (3.22)$$

Abb. 3.12 zeigt Realisierungen eines AR(1)-Prozesses mit $\varepsilon_t \propto \mathcal{N}(0, 1)$ für unterschiedliche Werte von ϕ . Für eine ausführliche Betrachtung von AR-Prozessen siehe z.B. (BJRL15, KWH13).

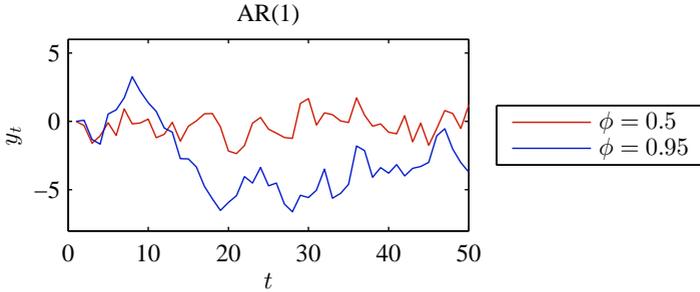


Abb. 3.12: Beispielhafte Realisierungen eines AR(1)-Prozesses y_t mit einer Innovation $\varepsilon_t \sim \mathcal{N}(0, 1)$ und AR-Koeffizient $\phi = 0.5$ bzw. 0.95 .

Wird folgend vorausgesetzt, dass das Niveau der Geschwindigkeit der Verteilung V_Z und das Zeitverhalten einem AR(1)-Prozess folgt, kann der kombinierte Prozess der Zielgeschwindigkeit formuliert werden als

$$\begin{aligned}
 v_{AR,t} &= (1 - \delta_t)(\phi v_{AR,t-1} + \varepsilon_t), & \varepsilon_t &\sim \mathcal{N}(0, \sigma_\varepsilon^2) \\
 v_{\mu,t} &= \delta_t \alpha_t + (1 - \delta_t)v_{\mu,t-1}, & \alpha_t &\sim V_Z \\
 v_{Z,t} &= v_{\mu,t} + v_{AR,t}, & & (3.23) \\
 \delta_t &= \begin{cases} 1 & \text{falls } v_{lim,t} \neq v_{lim,t-1} \\ 0 & \text{sonst} \end{cases} \text{.(FHFG17)}
 \end{aligned}$$

Dabei ist $v_{lim,t}$ das zum Zeitpunkt t dominierende, also das Fahrerverhalten bestimmende Geschwindigkeitslimit und $v_{Z,t}$ die Zielgeschwindigkeit zum Zeitpunkt t . Die Zielgeschwindigkeit $v_{Z,t}$ wird dabei aus dem Mittelwertprozess $v_{\mu,t}$ und dem autoregressiven Anteil $v_{AR,t}$ zusammengesetzt. Die Zielgeschwindigkeit ist dabei eine Realisierung der Verteilung V_Z , wenn sich das dominierende Geschwindigkeitslimit geändert hat. Bei gleichbleibendem dominierendem Geschwindigkeitslimit ist die Zielgeschwindigkeit die Realisierung eines autoregressiven Prozesses. Eine ausführlichere Betrachtung der Prozessparameter dieses Modells erfolgt in Abschnitt 3.6.

Der in Gleichung 3.23 beschriebene Prozess der Zielgeschwindigkeit wird im Folgenden mit Γ_v bezeichnet.

Fahrerwunschedynamik

Die übrigen, in der Prozessmodellierung noch nicht diskutierten Parameter der Transferfunktion, beschreiben das dynamische Verhalten und lassen sich somit dem Begriff der Fahrerwunschedynamik bzw. Fahrstil zuordnen. Ähnlich wie bei der Zielgeschwindigkeit liegt auch hier das Problem der eingeschränkten Beobachtbarkeit vor: So sind Beschleunigungs- und Verzögerungsvorgänge weder scharf abgrenzbar, noch sind die hervorrufenden Einflüsse genau zu identifizieren. So kann z.B. der Beschleunigungsvorgang bei einer Änderung des Geschwindigkeitslimits durch andere Einschränkungen wie Verkehr oder Kurven beeinflusst sein. Ähnlich ist auch bei Kurvenfahrten nicht eindeutig identifizierbar, ob eine vorliegende Kurve eine relevante Einschränkung darstellt und die beobachtete Querschleunigung somit als charakteristische Größe betrachtet werden kann.

Neben der Unsicherheit durch die eingeschränkte Beobachtung sind auch andere Unsicherheiten zu berücksichtigen. So können sowohl Änderungen des Fahrerhaltens durch Umgebungsfaktoren als auch durch Zeitabhängigkeiten auftreten. Neben diesen selbstgesteuerten Änderungen kann beispielsweise durch vorausfahrenden Verkehr eine erzwungene Änderung der Dynamik erfolgen. Dabei ist sowohl das Verhalten vorausfahrender Fahrzeuge, wie auch deren Existenz bzw. Relevanz über einen längeren Vorhersagehorizont ein Unsicherheitsfaktor. Diese Einflussfaktoren stellen eine Herausforderung für die Modellierung dar.

Werden die oben genannten Parameter zum Beispiel unabhängig voneinander betrachtet, bedeutet das bei einem Wechsel in der Dynamik des Fahrers, dass zunächst auch alle Parameter getrennt beobachtet und adaptiert werden müssen, bevor das System sich an die geänderten Dynamikanforderungen angepasst hat. Dies kann für den Fahrer zu unplausiblen Systemreaktionen führen, da trotz dynamischer Beschleunigung von einer ruhigen Kurvenfahrt ausgegangen wird. Im Kontext mit Fahrzeugdynamikvorhersagen ist es daher sinnvoll von einem „monotonen“ Zusammenhang zwischen Fahrstil und Dynamik auszugehen, also Abstufungen von ruhiger bis dynamischer Fahrweise (siehe auch Abschnitt 3.2.1). Dadurch wird eine Konsistenz des geschätzten Zustandes der Fahrerwunschedynamik gewährleistet und die Möglichkeit der zügigen Adaption auf plötzliche Änderungen (z.B. durch aufkommenden Verkehr) geschaffen. Im Ge-

genzug werden Freiheitsgrade in der Parametrierung der Fahrerwunschdynamik aufgegeben.

Eine Möglichkeit die Schätzung von nicht direkt beobachtbaren Zuständen mit stochastischem Zeitverhalten zu verknüpfen, sind Hidden Markov Models (HMM).

Ein Hidden Markov Model (HMM) besteht aus einer Markov-Kette, die nicht direkt beobachtbar ist und daher als versteckter Prozess bezeichnet wird. Ein zweiter Prozess, dessen Zustände mit den versteckten Zuständen der Markov-Kette in Verbindung stehen, ist beobachtbar und wird daher als Beobachtungsprozess bezeichnet. Der Beobachtungsprozess besteht aus dem Vektor der Beobachtungsgrößen O_t , die Zustände der Markov-Kette werden als S_t bezeichnet. Der Beobachtungsprozess wird durch die Beobachtungswahrscheinlichkeit $P(O_t|S_t)$ definiert. Der Wert $P(O_t|S_t)$ gibt an, mit welcher Wahrscheinlichkeit die Beobachtung O_t gemacht wird, wenn die Markov-Kette im Zustand S_t ist.

Das Zeitverhalten der Zustände des HMM wird über die Übergangsmatrix M der Markov-Kette beschrieben (siehe auch Gl. 3.10).

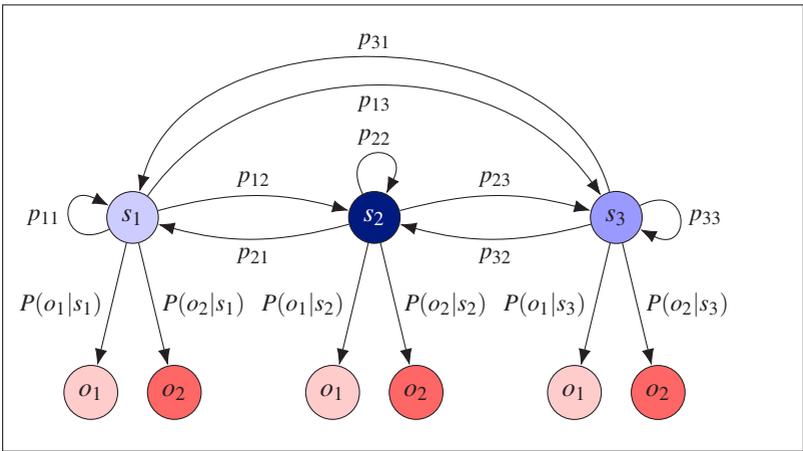


Abb. 3.13: Hidden Markov Model mit einer Markov-Kette S_t mit drei Zuständen (s_1, s_2, s_3) und deren Übergangswahrscheinlichkeiten p_{ij} , einer Beobachtungsgröße O_t mit zwei Zuständen (o_1, o_2) sowie den Beobachtungswahrscheinlichkeiten $P(o_j|s_i)$ für die Beobachtung von $O_t = o_j$ bei Zustand $S_t = s_i$.

Die Zustände des HMM werden – wie in (FHFG17) – für mögliche Zustände der Fahrerwunschkennlinie eingesetzt. Jedem Zustand $i \in \mathcal{S}$ wird daher ein Tupel $\tilde{\gamma}_{d,i}$ mit

$$\tilde{\gamma}_{d,i} = [a_{x,max,i}, a_{x,min,i}, a_{y,max,i}, P_{max,i}, j_{max,i}]^T \quad (3.24)$$

zugeordnet, das die dem Zustand zugeordneten Parameterwerte definiert. Die Menge aller möglichen Zustände wird mit $\mathcal{S} = \{1, \dots, N_{HMM}\}$ bezeichnet. Die Markov-Kette definiert somit die Häufigkeit des Auftretens dieser Fahrerwunschkennlinie-Zustände sowie deren Übergangswahrscheinlichkeiten.

Die Modellierung der Beobachtungswahrscheinlichkeiten $P(O_t|S_t)$ kann auf unterschiedliche Weise erfolgen. Für einen diskreten Wertebereich der Beobachtungsgröße kann eine Matrix der Beobachtungswahrscheinlichkeiten aufgestellt werden. Für einen kontinuierlichen Bereich wird $P(O_t|S_t)$ häufig über Gaußverteilungen oder GMMs modelliert. Ist eine Beobachtungsreihe $O_{1:T}$ gegeben, kann durch das Beobachtungsmodell mittels Bayes'scher Inferenz auf die Zustandswahrscheinlichkeiten $P(S_t)$ des versteckten Prozesses geschlossen werden. Ein geeignetes Beobachtungsmodell vorausgesetzt, kann das HMM somit zur Beobachtung und Vorhersage der Fahrerwunschkennlinie verwendet werden. Die Herleitung eines geeigneten Beobachtungsmodells und die Bestimmung der Zustandswahrscheinlichkeiten wird in Abschnitt 3.6 behandelt.

Der Prozess, der das Zeitverhalten der Markov-Kette auf den Parametervektor $[a_{x,max}, a_{x,min}, a_{y,max}, P_{max}, j_{max}]^T$ abbildet, wird als Fahrerwunschkennlinieprozess Γ_d bezeichnet.

Das Prozessmodell

In den vorhergehenden Abschnitten wurden zunächst die stochastischen Modellierungsmöglichkeiten für die Parameter γ diskutiert. Dabei wurden stochastische Prozesse hergeleitet, die geeignet sind, das Verhalten und die Unsicherheit der unterschiedlichen Einflussgrößen zu beschreiben. Zusammenfassend wird der Prozess, der das stochastische Verhalten aller Parameter abbildet, mit Γ bezeichnet. Es gilt somit:

$$\gamma_t \sim \Gamma. \quad (3.25)$$

Der Zeitdiskretisierung des Prozesses wird als Vielfaches der Zeitdiskretisierung $\Delta t = 1$ s definiert. Hierfür wird der Zeitschrittfaktor $c_{t,\Gamma}$ eingeführt. Die Schrittweite des Prozesses sollte so gewählt werden, dass das Verhalten bzw. die Frequenz der Änderungen im Verhalten abgebildet werden können. Da die Parameter der Transferfunktion im wesentlichen Charakteristiken der Manöverebene des Fahrers beschreiben, wird im Folgenden eine eher große Zeitschrittweite von $c_{t,\Gamma} \cdot \Delta t = 5$ s für den stochastischen Prozess gewählt, um diese Charakteristiken geeignet zu erfassen.

3.6 Parameterinferenz

Während sich bei einer deterministischen Betrachtung die Fahreradaptation als Schätzproblem der Parameter γ darstellt, ist für die stochastische Modellierung das Schätzen der Prozessparameter von Γ notwendig. In diesem Abschnitt wird die Ermittlung dieser Prozessparameter behandelt.

Der Zielgeschwindigkeitsprozess Γ_v wird durch die aktuelle Zielgeschwindigkeit $v_{Z,t}$, die Parameter des autoregressiven Prozesses (ϕ , σ_ε) und die Parameter der Verteilung V_Z (μ_Δ , σ_Δ , μ_{max} , σ_{max}) definiert. Um die Parameter der stochastischen Beschreibung zu ermitteln, muss zunächst ein Verfahren zur Beobachtung der Zielgeschwindigkeit definiert werden. Anschließend können die übrigen Parameter aus dem Verhalten von v_Z abgeleitet werden.

Der Fahrerwunschdynamikprozess Γ_d wird durch die Wahrscheinlichkeitsverteilung des aktuellen Zustands π_t und die Übergangsmatrix M beschrieben. Ein geeignetes Beobachtungsmodell $P(O_t|S_t)$ zur Ermittlung der Zustandswahrscheinlichkeiten ist ebenfalls zu ermitteln.

Der die Routenoptionen abbildende Prozess Γ_r , ist im Rahmen dieser Arbeit durch das in Abschnitt 3.5.2 beschriebene Verfahren (siehe Gl. (3.17) bzw. Gl. (3.18)) definiert. Da hierfür nur statische Parameter verwendet werden, ist keine Online-Identifikation notwendig.

Zur Ermittlung der Prozessparameter von Γ muss somit der Vektor ϑ mit

$$\vartheta = \{\hat{v}_{Z,t}, \pi_t\} \tag{3.26}$$

bestimmt werden, wobei $\hat{v}_{Z,t}$ der aktuelle Schätzwert der Zielgeschwindigkeit und π_t die Verteilung der Zustandswahrscheinlichkeiten des HMM ist. Die Prozessparameter von Γ werden zu

$$\theta = \{\phi, \sigma_\varepsilon, \mu_\Delta, \sigma_\Delta, \mu_{max}, \sigma_{max}, M\} \quad (3.27)$$

zusammengefasst und sind aus dem Zeitverhalten von ϑ abzuleiten.

3.6.1 Methodik zur Verifizierung

Reale Messfahrten sind von zentraler Bedeutung für die Validierung des Vorhersagemodells. Um den Entwurf des stochastischen Modells zu validieren, muss aber zunächst das Verfahren zur Parameteridentifikation verifiziert werden. Die Verifikation kann dabei nicht direkt mit den realen Messfahrten durchgeführt werden, da es keine objektive Referenz für die Prozessparameter θ gibt. Die grundsätzliche Eignung des Modells (Validierung) und die Korrektheit der Parameteridentifikation (Verifikation) müssen daher getrennt voneinander betrachtet werden.

Zur Verifikation der Parameterschätzung bietet sich die Generierung eines künstlichen Datensatzes an, da in diesem Fall eine objektive Referenz für die Prozessparameter und Beobachtungsgrößen existiert und die Parameterinferenz somit bewertet werden kann. Für die Verifikation der Parameterinferenz wird daher zunächst davon ausgegangen, dass das Verhalten des Fahrers der zuvor formulierten Prozessformulierung folgt und entsprechende Testdaten mit dem Modell selbst erzeugt.

Erzeugung virtueller Testdaten:

Zur Datenerzeugung werden die Streckendaten der Teststrecke (Abschnitt 3.4) verwendet. Hierfür wird zunächst ein initialer Zustand S_0 für die Fahrerwunschnachdynamik sowie eine initiale Zielgeschwindigkeit $v_{Z,0}$ definiert. Das Zielsegment $s_{ID,t}$ wird jeweils entsprechend des gegebenen Streckenverlaufs gewählt. Damit sind die Parameter der Transferfunktion für den ersten Zeitschritt (γ_0) bestimmt.

Mit den Parametern γ_0 und einem initialen Zustand y_0 erfolgt die schrittweise Berechnung einer Trajektorie \underline{y} mit

$$y_{t+1} = f_T(y_t, s_t, \gamma_t, \mathcal{T}_{PSD,t}), \forall t. \quad (3.28)$$

Siehe hierzu auch Abschnitt 3.5.1. Für die Parameter γ_t gilt dabei entsprechend der Prozessbeschreibung:

$$\gamma_t = \begin{cases} \gamma_t \sim \Gamma & \text{falls } t = k \cdot c_{t,\Gamma}, k \in \mathbb{N} \\ \gamma_{t-1} & \text{sonst} \end{cases} . \quad (3.29)$$

Abb. 3.14 zeigt einen beispielhaften Geschwindigkeitsverlauf für die Initialzustände $v_{Z,0} = v_{lim,0}$ und $S_0 = 3$ mit den Prozessparametern:

$$\begin{aligned} \theta &= \{ \phi, \sigma_\varepsilon, \mu_\Delta, \sigma_\Delta, \mu_{max}, \sigma_{max}, M \} , \\ &= \{ 0.9, 1.0\text{m/s}, 0\text{m/s}, 1.0\text{m/s}, 40\text{m/s}, 0\text{m/s}, M \} \end{aligned} \quad (3.30)$$

und der Übergangsmatrix

$$\begin{aligned} M &= [p_{ij}]_{5 \times 5} , \\ p_{ij} &= \begin{cases} 0.95 & \text{falls } i = j \\ 0.0125 & \text{sonst} \end{cases} . \end{aligned} \quad (3.31)$$

Diese Werte der Übergangsmatrix führen zu einer mittleren Aufenthaltsdauer von 100s für einen Fahrerwunschdynamik-Zustand (Berechnung siehe Anhang A.3). Auf Grund der symmetrischen Matrix treten dabei alle Zustände der Fahrerwunschdynamik gleich wahrscheinlich auf.

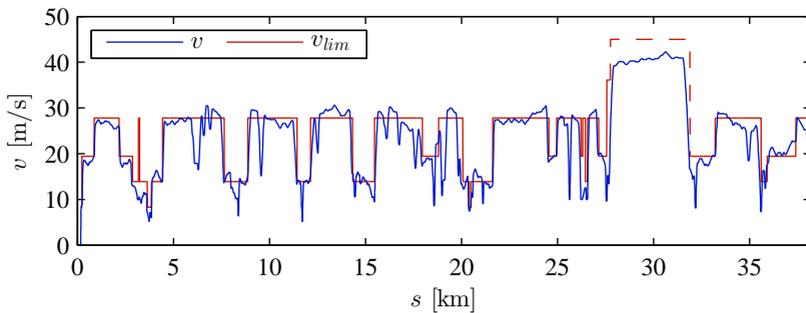


Abb. 3.14: Geschwindigkeitsverlauf v und Geschwindigkeitsbeschränkung v_{lim} über der Strecke s für eine beispielhafte Realisierung des stochastischen Prozesses Γ für die gewählte Teststrecke.

3.6.2 Rekursive Schätzverfahren

Zur Ermittlung der Prozessparameter wird eine Schätzfunktion $\hat{\theta}_i$ für den jeweiligen Parameter θ_i benötigt. Ist eine Beobachtungsreihe $x_{1:n}$ einer Zufallsvariablen x gegeben, wird eine Schätzfunktion für einen statistischen Parameter meist über eine Summenfunktion der Beobachtungsreihe definiert. Der Mittelwert μ und die Varianz σ^2 dieser Beobachtungsreihe werden z.B. über das arithmetische Mittel bzw. die korrigierte Stichprobenvarianz geschätzt:

$$\begin{aligned}\hat{\mu} &= \frac{1}{n} \sum_{i=1}^n x_i, \\ \hat{\sigma}^2 &= \frac{1}{n-1} \sum_{i=1}^n (x_i - \hat{\mu})^2.\end{aligned}\tag{3.32}$$

Die Schätzwerte sind somit in Form einer Funktion

$$\hat{\theta}_{i,n} = f(x_{1:n})\tag{3.33}$$

definiert.

Für Online-Parameterschätzungen (echtzeitfähige Schätzung zur Laufzeit der Funktion) ist diese Form der Schätzfunktion von Nachteil, da der Speicherbedarf der Beobachtungsreihe $x_{1:n}$ und die benötigte Rechenzeit zur Ermittlung des Schätzwertes mit der Länge der Zeitreihe (n) zunimmt. Ziel eines rekursiven Schätzverfahrens ist es daher, die Schätzfunktion über eine Rekursionsgleichung als rekursive Folge zu definieren. Die rekursive Schätzfunktion muss hierfür in einer Form

$$\hat{\theta}_{i,n} = f(\hat{\theta}_{i,n-1}) + f(x_n)\tag{3.34}$$

definiert werden, da so nur der letzte Schätzwert $\hat{\theta}_{i,n-1}$ und die neue Beobachtung x_n benötigt werden. Rechenzeit und Speicherbedarf sind somit begrenzt bzw. konstant.

Zur Schätzung von Parametern werden die Momentenmethode und die Maximum-Likelihood-Methode angewandt. Im Allgemeinen besitzen Schätzer basierend auf der Maximum-Likelihood-Methode überlegene statistische Eigenschaften gegenüber denen der Momentenmethode. In manchen Fällen kann die Berechnung der Maximum-Likelihood-Schätzwerte aber aufwendiger sein als mit der

Momentenmethode. Wegen dieser einfacheren Berechnungsweise wird häufig auch die Momentenmethode eingesetzt. (Haz11)

Zielgeschwindigkeit

Der erste Schritt in der Parameterschätzung des Zielgeschwindigkeitsprozesses Γ_z ist die Ermittlung einer Beobachtungsreihe $\hat{v}_{z,t}$. Dabei muss berücksichtigt werden, dass die Fahrgeschwindigkeit während Kurvenfahrten und Beschleunigungsvorgängen die Zielgeschwindigkeit unterschreitet. Die Zielgeschwindigkeit kann somit nicht durchgängig beobachtet werden. Im Folgenden wird ein Verfahren zur Filterung der Zielgeschwindigkeit beschrieben. Dabei wird bei Überschreitung der geschätzten Zielgeschwindigkeit die aktuelle Fahrgeschwindigkeit als neue Zielgeschwindigkeit übernommen. Bei Unterschreitung der Zielgeschwindigkeit wird diese nur übernommen, wenn Längs- und Querbeschleunigung für eine definierte Zeit unterhalb vorgegebener Schwellwerte bleiben („Konstantfahrt“). Bei einer Änderung der aktuellen Geschwindigkeitsbeschränkung wird die Zielgeschwindigkeit mit dem geschätzten mittleren Offset μ_Δ zu diesem Geschwindigkeitslimit reinitialisiert. Dieses Verfahren ist in Algorithmus 1 (S. 57) beschrieben.

Dabei ist zu berücksichtigen, dass die Beobachtungsreihe zur Parameterschätzung der Zeitdiskretisierung des Prozesses $c_{t,\Gamma} \cdot \Delta t$ folgen muss. Die Beobachtungsreihe mit dieser Zeitdiskretisierung wird im Folgenden $\hat{v}'_{z,t'}$ bezeichnet, wobei t' der zu t zugehörige Zeitindex mit der Schrittweite $c_{t,\Gamma}$ ist. Wird während $c_{t,\Gamma}$ Zeitschritten keine Beobachtung für $\hat{v}'_{z,t'}$ zugewiesen (*validObservation* in Alg. 1), wird die Beobachtung als fehlende Beobachtung behandelt. Fehlende Beobachtungen werden für die Parameterschätzung nicht berücksichtigt.

Abb. 3.15 zeigt beispielhafte Ausschnitte aus einer Messfahrt und die mit Algorithmus 1 identifizierte Beobachtungsreihe \hat{v}'_z . In Abb. 3.15(a) liegt eine Situation ohne Kurveneinschränkungen vor. Entsprechend ist die beobachtete Geschwindigkeit im Wesentlichen durch die Zielgeschwindigkeit bedingt und die Beobachtungsreihe \hat{v}'_z folgt entsprechend dem Geschwindigkeitsverlauf v . In Abb. 3.15(b) liegen zahlreiche Kurveneinschränkungen vor. Die Beobachtbarkeit der Zielgeschwindigkeit ist dadurch eingeschränkt. Zu Beginn des Abschnitts ($t \approx 1220s$) kann zunächst keine Beobachtung für die Zielgeschwin-

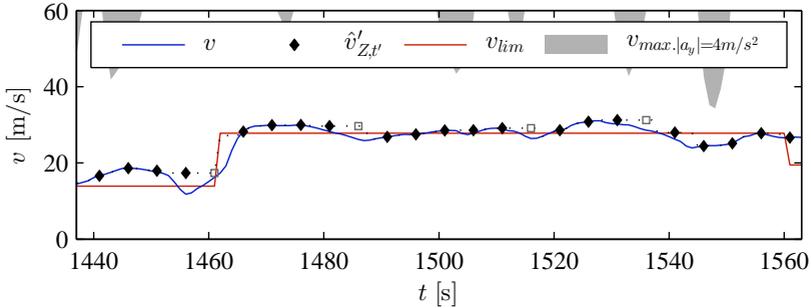
Algorithmus 1 : Filterung $\hat{v}_{Z,t}$ **Input** : $\underline{v}_{SL}, \underline{y}$ **Output** : \hat{v}_Z, \hat{v}'_Z **begin**

```

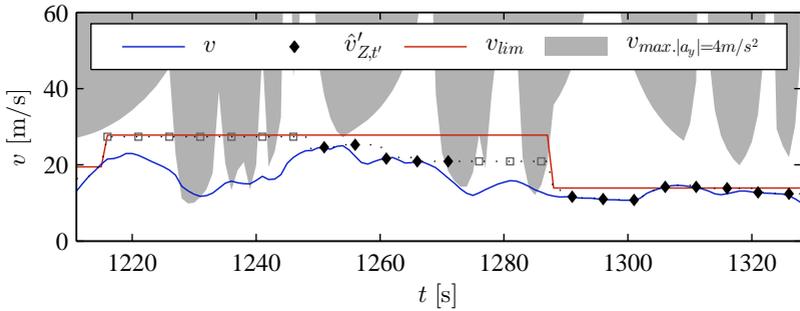
 $\hat{v}_{Z,0} \leftarrow v_{lim,0};$ 
for  $t \leftarrow 1, \infty$  do
     $validObservation \leftarrow false;$ 
    if  $v_{lim,t} \neq v_{lim,t-1}$  then
        /* Neues Geschwindigkeitslimit */
         $\hat{v}_{Z,t} \leftarrow v_{lim,t} + \mu_{\Delta};$ 
    if  $v_t \geq \hat{v}_{Z,t}$  then
        /* Erhöhung der Zielgeschwindigkeit */
         $\hat{v}_{Z,t} \leftarrow v_t;$ 
         $validObservation \leftarrow true;$ 
    else
        if  $|a_{x,t}| < a_{x,Grenz}$  &  $|a_{y,t}| < a_{y,Grenz}$  then
             $timer.start();$ 
        else
             $timer.stop(); timer.reset();$ 
        if  $timer.timeRunning() \geq t_{Grenz}$  then
            /* Verringerung der Zielgeschwindigkeit */
             $\hat{v}_{Z,t} \leftarrow v_t;$ 
             $timer.stop(); timer.reset();$ 
             $validObservation \leftarrow true;$ 
    if  $\sim validObservation$  then
         $\hat{v}_{Z,t} \leftarrow \hat{v}_{Z,t-1};$ 
    if  $|\hat{v}_{Z,t} - v_t| < \Delta v_{Grenz}$  then
         $validObservation \leftarrow true;$ 
    if  $validObservation$  then
         $\hat{v}'_{Z,t'} = \hat{v}_{Z,t};$ 

```

digkeit gemacht werden, weil die Beschleunigungsphase nach dem Wechsel des Geschwindigkeitslimits direkt in eine Verzögerung auf eine Kurve übergeht.



(a)



(b)

Abb. 3.15: Gefahrene Geschwindigkeit v , Beobachtungen der Zielgeschwindigkeit $\hat{v}'_{Z,t'}$ und Geschwindigkeitsbeschränkung v_{lim} für Ausschnitte aus Realfahrten ohne (a) und mit (b) relevanter Kurveneinschränkung. Fehlende Beobachtungen für $\hat{v}'_{Z,t'}$ werden durch leere Kästchen markiert.

Wie bereits zuvor geschildert, können die realen Messfahrten nur für eine subjektive Verifizierung der Zielgeschwindigkeitsidentifikation verwendet werden. In Abb. 3.16 ist die identifizierte Zielgeschwindigkeit für das Beispielprofil aus Abschnitt 3.6.1 dargestellt. Da das Profil simulativ erzeugt wurde, kann hier auch der tatsächliche Verlauf der Zielgeschwindigkeit v_Z abgebildet werden. Die mittlere absolute Abweichung zwischen tatsächlicher und geschätzter Ziel-

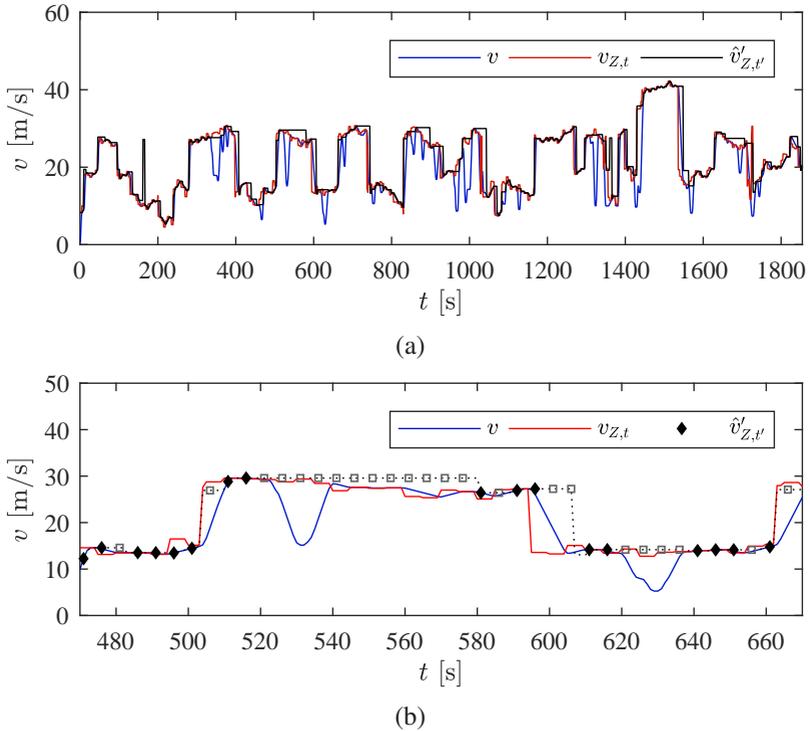


Abb. 3.16: Gefahrene Geschwindigkeit v , tatsächliche und geschätzte Zielgeschwindigkeit $v_{Z,t}$ und $\hat{v}'_{Z,t'}$ für die gesamte Teststrecke (a) und einen Ausschnitt (b).

geschwindigkeit beträgt für dieses Profil 0.93 m/s. In Abb. 3.16(b) ist erneut eine Situation mit mangelnder Beobachtbarkeit durch Kurven dargestellt. Diese Beispielsituation zeigt, dass Alg. 1 diese Änderungen erfolgreich von der Zielgeschwindigkeit separiert.

Mit der geschätzten Beobachtungsreihe \hat{v}'_Z können die zugehörigen Prozessparameter ermittelt werden. Da sich die Verteilung V_Δ relativ zum Geschwindigkeitslimit definiert, ist dies bei der Schätzung der Verteilungsparameter entsprechend zu berücksichtigen. Zufallsereignis ist in diesem Fall der Wechsel eines Geschwindigkeitslimits. Das heißt, der Mittelwert μ_Δ und die Standardabweichung σ_Δ können nicht direkt aus der Zeitreihe \hat{v}'_Z berechnet werden,

sondern müssen in eine Beobachtungsreihe über die Geschwindigkeitsbeschränkungen transformiert werden.

Aus der Beobachtungsreihe \hat{v}'_Z kann mit den jeweils gültigen Geschwindigkeitsbegrenzungen $v_{lim,i}$ die Reihe der Abweichungen \hat{v}_Δ mit

$$\hat{v}_{\Delta,t'} = \hat{v}'_{Z,t'} - v_{lim} \quad (3.35)$$

ermittelt werden. Der arithmetische Mittelwert, der zu einem Geschwindigkeitslimit $v_{lim,i}$ gehörigen Abweichungen, sei mit $\bar{v}_{\Delta,i}$ bezeichnet, die mittlere Zielgeschwindigkeit entsprechend $\bar{v}_{Z,i}$. Die Schätzwerte für V_Δ lassen sich dann mit

$$\begin{aligned} \hat{\mu}_{\Delta,n} &= \frac{1}{n} \sum_{i=1}^n \bar{v}_{\Delta,i}, \\ \hat{\sigma}_{\Delta,n}^2 &= \frac{1}{n-1} \sum_{i=1}^n (\bar{v}_{\Delta,i} - \hat{\mu}_{\Delta,n})^2, \quad n > 1 \end{aligned} \quad (3.36)$$

ermitteln. Gl. (3.36) lässt sich in eine rekursive Berechnungsvorschrift umwandeln (Herleitung siehe A.4). Die resultierende rekursive Schätzfunktion lautet:

$$\begin{aligned} \hat{\mu}_{\Delta,n} &= \frac{n-1}{n} \hat{\mu}_{\Delta,n-1} + \frac{1}{n} \bar{v}_{\Delta,n}, \\ \hat{\sigma}_{\Delta,n}^2 &= \frac{n-2}{n-1} \hat{\sigma}_{\Delta,n-1}^2 + \frac{1}{n} (\bar{v}_{\Delta,n} - \hat{\mu}_{\Delta,n-1})^2, \quad n > 1. \end{aligned} \quad (3.37)$$

Für viele Messungen ($n \rightarrow \infty$) hat eine einzelne Messung $\bar{v}_{\Delta,n}$ nur noch geringen Einfluss auf den Schätzwert. Da sich der beobachtete Prozess nicht zwangsläufig stationär verhält – also auch über der Zeit variieren kann – wird üblicherweise eine Begrenzung der Samplegröße für eine rekursive Berechnungsvorschrift vorgenommen. Dies ermöglicht eine Adaption auf Änderungen in den Parametern auch nach vielen Messungen. Die modifizierte Berechnungsvorschrift lautet dann

$$\begin{aligned} \hat{\mu}_{\Delta,n} &= \frac{\lambda-1}{\lambda} \hat{\mu}_{\Delta,n-1} + \frac{1}{\lambda} \bar{v}_{\Delta,n}, \\ \hat{\sigma}_{\Delta,n}^2 &= \frac{\lambda-2}{\lambda-1} \hat{\sigma}_{\Delta,n-1}^2 + \frac{1}{\lambda} (\bar{v}_{\Delta,n} - \hat{\mu}_{\Delta,n-1})^2, \quad n > 1, \end{aligned} \quad (3.38)$$

mit $\lambda = \min(n, n_{max})$.

Die Parameter der Verteilung bei unbeschränkter Strecke werden dementsprechend ermittelt. Die Schätzfunktion lautet hier dann

$$\begin{aligned}\hat{\mu}_{max,n} &= \frac{\lambda - 1}{\lambda} \hat{\mu}_{max,n-1} + \frac{1}{\lambda} \bar{v}_{Z,n}, \\ \hat{\sigma}_{max,n}^2 &= \frac{\lambda - 2}{\lambda - 1} \hat{\sigma}_{max,n-1}^2 + \frac{1}{\lambda} (\bar{v}_{Z,n} - \hat{\mu}_{max,n-1})^2, \quad n > 1, \\ \text{mit } \lambda &= \min(n, n_{max}).\end{aligned}\tag{3.39}$$

Mit dem Verfahren zur Identifikation der Zielgeschwindigkeit (Alg. 1) und den rekursiven Berechnungsvorschriften (Gl. (3.38) und (3.39)) kann die Parameterinferenz des Zielgeschwindigkeitsprozesses verifiziert werden. Hierfür werden die Parameter μ_Δ und σ_Δ variiert und ein entsprechendes Set virtueller Testfahrten erzeugt. Die übrigen Parameter werden dabei wie in Abschnitt 3.6.1 beschrieben gesetzt. Insgesamt werden 50 Simulationen mit $\mu_\Delta \sim \mathcal{U}(-5\text{m/s}, 5\text{m/s})$ und $\sigma_\Delta \sim \mathcal{U}(0\text{m/s}, 3\text{m/s})$ durchgeführt.

Abb. 3.17 zeigt die Schätzwerte der Parameter am Ende der jeweiligen Testfahrt. Wie in Abb. 3.17 (a) ersichtlich konvergieren die Schätzwerte $\hat{\mu}_\Delta$ zu den realen Werten μ_Δ (Punktwolke um Ursprungsgerade mit Steigung 1). Die Schätzwerte $\hat{\sigma}_\Delta$ hingegen liegen vor allem für kleine σ_Δ etwas oberhalb der tatsächlichen Werte. Für kleine Standardabweichungen σ_Δ wird die Unsicherheit somit überschätzt. Die Wurzel des mittleren quadratischen Fehlers (RMSE - *root mean square error*) für beide Schätzwerte liegt dabei in einem Bereich < 1 m/s und ist somit relativ gering.

Die systematische Überschätzung der Streuung für kleine σ_Δ ist durch die Überlagerung des autoregressiven Prozesses zu erklären, der selbst für den theoretischen Fall $\sigma_\Delta = 0$ zu einem Erwartungswert $\mathbb{E}(\hat{\sigma}_\Delta) > 0$ führt. Da $\hat{\mu}_{\Delta,n}$ der geschätzte Mittelwert eines AR(1)-Prozesses⁹ ist, gilt für $\mathbb{E}(\hat{\sigma}_\Delta^2)$:

$$\mathbb{E}(\hat{\sigma}_\Delta^2) = \text{Var}(\hat{\mu}_\Delta) = \mathbb{E}(\hat{\mu}_\Delta^2) - \mathbb{E}(\hat{\mu}_\Delta)^2.\tag{3.40}$$

⁹ Autoregressiver Prozess erster Ordnung

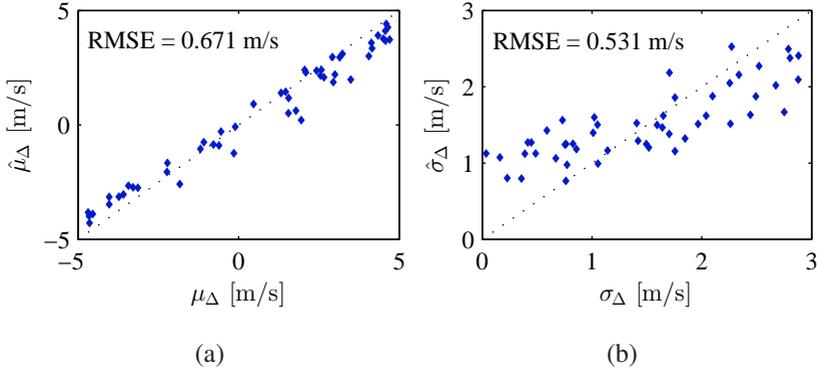


Abb. 3.17: Schätzwerte für Mittelwert $\hat{\mu}_\Delta$ (a) und Standardabweichung $\hat{\sigma}_\Delta^2$ (b) für die Verteilung V_Z des Geschwindigkeitsniveaus, dargestellt über die tatsächlich simulierten Werten der Parameter für 50 zufällige Konfigurationen von μ_Δ und σ_Δ .

Für den AR(1)-Prozess aus Gl. (3.23) gilt $\mathbb{E}(\hat{\mu}_\Delta) = 0$ (KWH13). Damit folgt weiter:

$$\mathbb{E}(\hat{\sigma}_\Delta^2) = \mathbb{E}(\hat{\mu}_\Delta^2) = \frac{1}{n} \sum_{i=1}^n \hat{\mu}_\Delta^2 > 0. \tag{3.41}$$

Da sehr geringe Standardabweichungen σ_Δ als theoretischer Grenzfall zu betrachten sind (idealisiertes Fahrerverhalten), kann die Verzerrung des Schätzwertes in diesem Bereich toleriert werden.

Parameter des AR(1)-Prozesses: Neben den Parametern der Verteilung V_Z müssen die Parameter des autoregressiven Prozesses ($\phi, \sigma_\varepsilon^2$) geschätzt werden. Sei zunächst $v_{AR,t}$ eine Zeitreihe realisiert durch einen AR(1)-Prozess. Der ML-Schätzwert (Maximum Likelihood) für ϕ kann nur durch numerische Minimierungsverfahren ermittelt werden (CC08), wodurch dieser für eine Online-Schätzung nicht in Frage kommt. Abhilfe bieten hier die CML-Schätzwerte (Conditional Maximum Likelihood) unter Bedingung der ersten Beobachtung x_1 . Der CML-Schätzwert für ϕ ist durch

$$\hat{\phi}_n^{CML} = \frac{\sum_{t'=2}^n (v_{AR,t'} - \bar{v}_{AR})(v_{AR,t'-1} - \bar{v}_{AR})}{\sum_{t'=2}^n (v_{AR,t'-1} - \bar{v}_{AR})^2} \tag{3.42}$$

gegeben. Der CML-Schätzwert für σ_ε^2 ist durch

$$\hat{\sigma}_{\varepsilon,n}^2{}^{CML} = \frac{1}{n-1} \sum_{t'=2}^n [(v_{AR,t'} - \bar{v}_{AR}) - \phi(v_{AR,t'-1} - \bar{v}_{AR})]^2 \quad (3.43)$$

gegeben. Da sich die CML-Schätzwerte für große Samplegrößen nicht von den exakten ML-Schätzwerten unterscheiden, können diese als einfacher handhabbare Alternative eingesetzt werden (CC08).

Die rekursiven Berechnungsvorschriften für die Schätzwerte $\hat{\phi}_n^{CML}$ und $\hat{\sigma}_{\varepsilon,n}^2{}^{CML}$ werden in Anhang A.5 hergeleitet.

Für die Schätzung der AR-Parameter ist zu beachten, dass $v_{AR,t'}$ nicht der beobachteten Zeitreihe v_Δ entspricht, da diese durch die Verteilung V_Z mittelwertsbehaftet ist und zusätzlich Sprünge in der Zeitreihe bei einem Wechsel der Geschwindigkeitsbeschränkung auftreten können. Die Zeitreihe \hat{v}_Δ muss also zunächst in eine mittelwertsfreie Zeitreihe umgewandelt werden. Die mittelwertsfreie Beobachtungsreihe ist

$$\hat{v}_{AR,t'} = \hat{v}_{\Delta,t'} - \bar{v}_{\Delta,i}, \quad (3.44)$$

wobei $\bar{v}_{\Delta,i}$ die mittlere Abweichung von der geltenden Geschwindigkeitsbeschränkung $v_{lim,i}$ ist. Für ein rekursives Verfahren ist diese Umwandlung nicht exakt möglich, da $\bar{v}_{\Delta,i}$ immer erst nach Beendigung eines Beschränkungsabschnittes ermittelt werden kann. Um die rekursive Berechnung zu ermöglichen, kann für $\bar{v}_{\Delta,i}$ als Schätzwert die erste Beobachtung v_{Δ,t_1} dieses Beschränkungsabschnittes verwendet werden. Dadurch ergibt sich die Zeitreihe

$$\hat{v}'_{AR,t'} = \hat{v}_{\Delta,t'} - v_{\Delta,t_1}. \quad (3.45)$$

Für die Verifizierung werden jetzt die Parameter ϕ und σ_ε variiert, die übrigen Parameter werden erneut, wie in Abschnitt 3.6.1 beschrieben, gesetzt. Es werden 50 Simulationen mit $\phi \sim \mathcal{U}(0.5, 1.0)$ und $\sigma_\varepsilon \sim \mathcal{U}(0 \text{ m/s}, 2 \text{ m/s})$ durchgeführt.

Abb. 3.18 zeigt die Schätzwerte für ϕ und σ_ε . Die Varianz σ_ε wird in beiden Fällen für größere σ_ε leicht unterschätzt. Auffällig ist die schlechte Schätzung des Parameters ϕ , wobei ϕ vor allem für kleinere Werte deutlich überschätzt wird. Dabei ist zu beachten, dass die beobachtbare Zeitreihe der Geschwindigkeit durch das Fahrer- und Fahrzeugverhalten gefiltert ist und daher Änderungen der

Zielgeschwindigkeit nicht unmittelbar folgt. Siehe hierzu auch das Beispiel in Anhang A.6. In diesem Beispiel wird ein AR(1)-Prozess mit der durch ein PT₁-Glied gefilterten Zeitreihe des Prozesses verglichen. Das Beispiel verdeutlicht, dass die beobachtete Zeitreihe eine deutlich höhere Autokorrelation aufweist, als der erzeugende AR(1)-Prozess. Weiterhin ist mit einer Unterschätzung der Autokovarianz und damit σ_ε zu rechnen. Das Beispiel zeigt, dass eine geringe Autokorrelation ϕ in einer solchen Situation nur bedingt beobachtbar ist, da die resultierende Geschwindigkeitstrajektorie eine systematisch höhere Korrelation aufweist.

Da der Parameter ϕ wegen der eingeschränkten Beobachtbarkeit nicht zufriedenstellend geschätzt werden kann, wird eine Annahme für den Parameter basierend auf den Realfahrdaten ermittelt. Eine entsprechende Untersuchung hierzu wird in Abschnitt 3.8 durchgeführt. Im Folgenden wird zunächst von einem bekannten Parameter ϕ ausgegangen. Abb. 3.19 zeigt die Schätzwerte für ϕ und σ , unter Annahme eines bekannten Parameters ϕ . Die Schätzwerte für σ_ε^2 weisen bei Bekanntheit des Parameters ϕ nochmals einen etwas geringeren Fehler auf als zuvor.

Mit Ausnahme des Autokorrelationsparameters ϕ können die Parameter des Zielgeschwindigkeitsprozesses somit mit hinreichender Genauigkeit rekursiv ermittelt werden.

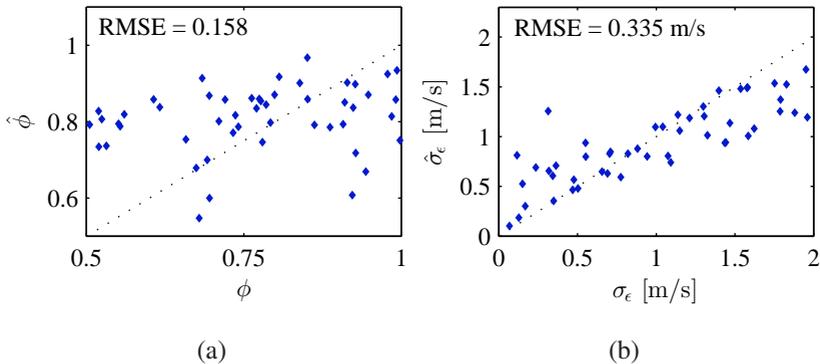


Abb. 3.18: Schätzwerte $\hat{\phi}$ (a) und $\hat{\sigma}_\varepsilon$ (b) des AR(1)-Prozess, dargestellt über den tatsächlich simulierten Werten für 50 zufällige Kombinationen von ϕ und σ_ε .

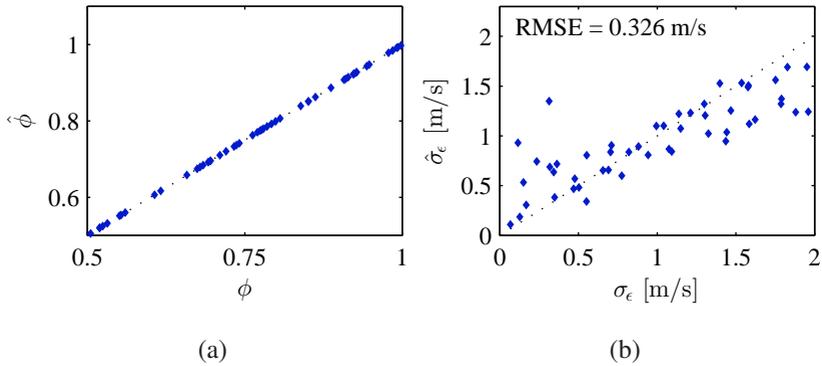


Abb. 3.19: Schätzwerte $\hat{\phi}$ (a) und $\hat{\sigma}_\varepsilon$ (b) des AR(1)-Prozess bei Annahme eines bekannten Parameters ϕ ($\hat{\phi} = \phi$), dargestellt über den tatsächlich simulierten Werten für 50 zufällige Kombinationen von ϕ und σ_ε .

Fahrerwunschkynamik

Ähnlich zum Prozess der Zielgeschwindigkeit, muss auch zur Ermittlung der Parameter der Fahrerwunschkynamik zunächst eine Beobachtungsreihe ermittelt werden. Bei einem HMM ist dies die zeitabhängige Wahrscheinlichkeitsverteilung π_t der Zustände. Hierfür muss ein Beobachtungsmodell $P(O_t|S_t)$ definiert werden. Dieses Modell gibt dabei die Wahrscheinlichkeit einer Beobachtung O_t für den Zustand S_t an. Da die Zustände S_t die Fahrerwunschkynamik repräsentieren, ist es naheliegend die Größen a_{x+} , a_{x-} und a_y als Beobachtungsgrößen zu verwenden, wobei

$$\begin{aligned}
 a_{x+} &= \begin{cases} a_x, & \text{falls } a_x \geq 0 \\ 0, & \text{sonst} \end{cases} \\
 a_{x-} &= \begin{cases} a_x, & \text{falls } a_x < 0 \\ 0, & \text{sonst} \end{cases}
 \end{aligned} \tag{3.46}$$

gilt.

Da der Prozesszeitschritt $c_{t,\Gamma} \cdot \Delta t$ größer als die Abtast-Schrittweite der Beobachtungsreihe (a_{x+}, a_{x-}, a_y) ist, werden die Beobachtungsgrößen wie folgt definiert:

$$O_t = \begin{bmatrix} O_{1,t} \\ O_{2,t} \\ O_{3,t} \end{bmatrix} = \begin{bmatrix} \max_{t \in c_{t,\Gamma}} a_{x+}(t) \\ \min_{t \in c_{t,\Gamma}} a_{x-}(t) \\ \max_{t \in c_{t,\Gamma}} |a_y(t)| \end{bmatrix}. \quad (3.47)$$

Für jede der Beobachtungsgrößen $O_{i,t}$ wird eine Beobachtungswahrscheinlichkeit $P(O_{i,t}|S_t)$ gebildet. Die kombinierte Beobachtungswahrscheinlichkeit für die vektorielle Beobachtungsgröße ist dann durch Linearkombination der einzelnen Beobachtungswahrscheinlichkeiten mit

$$P(O_t|S_t) = P(O_{1,t}|S_t) \cdot P(O_{2,t}|S_t) \cdot P(O_{3,t}|S_t) \quad (3.48)$$

gegeben.

Die Anzahl der verwendeten Markov-Zustände für das Hidden-Markov-Modell legt die Diskretisierung der Fahrerwunschkennlinie und damit die Genauigkeit und Flexibilität der Abbildung fest. Die Anzahl der sinnvollen Zustände ist aber auch durch die Beobachtbarkeit und Trennbarkeit dieser Zustände beschränkt. Im Folgenden werden als Kompromiss aus Beobachtbarkeit und Genauigkeit der Darstellung fünf Fahrerwunschkennlinie-Zustände für das Hidden-Markov-Modell gewählt. Längs- und Querdynamikparameter werden dabei äquidistant im relevanten Bereich verteilt. Zur Definition einer Radleistungsgrenze kann die Verteilung der Beschleunigungen über der Geschwindigkeit hinzugezogen werden (siehe Abb. A.2). Unter Berücksichtigung dieser Daten wird für die Radleistungsgrenze die benötigte Radleistung zur Erreichung der Maximalbeschleunigung a_x auf ebener Straße bei 100 km/h gewählt. Dieser Wert wird als $P_{a_x}^{100}$ bezeichnet. Die Ruckgrenze wird so gewählt, dass die Maximalbeschleunigung innerhalb von zwei Sekunden aufgebaut wird. Die entsprechenden Parametertupel sind in Tabelle 3.2 aufgeführt.

Zur Verifikation des Beobachtungsmodells werden fünf Simulationen durchgeführt, wobei der Fahrerwunschkennlinie-Zustand S_t jeweils konstant auf einen der fünf Zustände gesetzt wird. Die übrigen Parameter werden entsprechend Abschnitt 3.6.1 gewählt. Abb. 3.20(a) zeigt beispielhaft die relative Häufigkeitsverteilung für die positiven Längsbeschleunigungen a_{x+} . Dabei

Tabelle 3.2: Parametertupel $\tilde{\gamma}_{d,S^i}$ der den Markov-Zuständen i zugeordneten Fahrerwunschkennlinienparametern: Längsbeschleunigungs- und Längsverzögerungsgrenzen $a_{x,max}$ und $a_{x,min}$, tolerierte Querbeschleunigung $a_{y,max}$, Radleistungsgrenze P_{max} und Rückgrenze j_{max} .

	$a_{x,max}$	$a_{x,min}$	$a_{y,max}$	P_{max}	j_{max}
$\tilde{\gamma}_{d,1}$	1.5 m/s ²	-1.5 m/s ²	2.0 m/s ²	$P_{1.5m/s^2}^{100}$	0.75 m/s ³
$\tilde{\gamma}_{d,2}$	2.25 m/s ²	-2.25 m/s ²	3.0 m/s ²	$P_{2.25m/s^2}^{100}$	1.125 m/s ³
$\tilde{\gamma}_{d,3}$	3.0 m/s ²	-3.0 m/s ²	4.0 m/s ²	$P_{3.0m/s^2}^{100}$	1.5 m/s ³
$\tilde{\gamma}_{d,4}$	3.75 m/s ²	-3.75 m/s ²	5.0 m/s ²	$P_{3.75m/s^2}^{100}$	1.875 m/s ³
$\tilde{\gamma}_{d,5}$	4.5 m/s ²	-4.5 m/s ²	6.0 m/s ²	$P_{4.5m/s^2}^{100}$	2.25 m/s ³

ist zu beachten, dass diese Verteilungen synthetische Charakteristiken aufweisen, da das Simulationsmodell die exakten Grenzwerte für Längs- und Querbeschleunigungen einregelt. Das Beispiel zeigt, dass auch für den dynamischsten Fahrerzustand $S_t = 5$ situationsbedingt Beschleunigungen kleiner des entsprechenden Grenzwerts auftreten. Dieser Effekt zeigt sich auch für die übrigen Beobachtungsgrößen, da beispielsweise die Querbeschleunigung nicht nur von der Fahrerwunschkennlinie abhängt, sondern auch der Kurvigkeit der Strecke und den gesetzlichen Geschwindigkeitsbeschränkungen. Diese Häufigkeitscharakteristiken müssen im Beobachtungsmodell berücksichtigt werden. Grundsätzlich wird als Beobachtungsmodell daher ein Gaussian Mixture Model (GMM) bestehend aus zwei Gaußverteilungskomponenten gewählt, wobei eine Komponente den Mittelwert null besitzt und die andere einen Mittelwert entsprechend des Zustands der Fahrerwunschkennlinie. Abb. 3.20(b) zeigt ein solches Beobachtungsmodell beispielhaft für die Längsbeschleunigung ($O_{1,t}$).

Sind das Beobachtungsmodell $P(O_t|S_t)$ und die Zustandsübergangsmatrix M der Markov-Zustände gegeben, können für eine Beobachtungsreihe O_t die Zustandswahrscheinlichkeiten π_t mit der forward-backward Zerlegung nach (BPSW70) ermittelt werden. Sei folgend K die Anzahl der Markov-Zustände

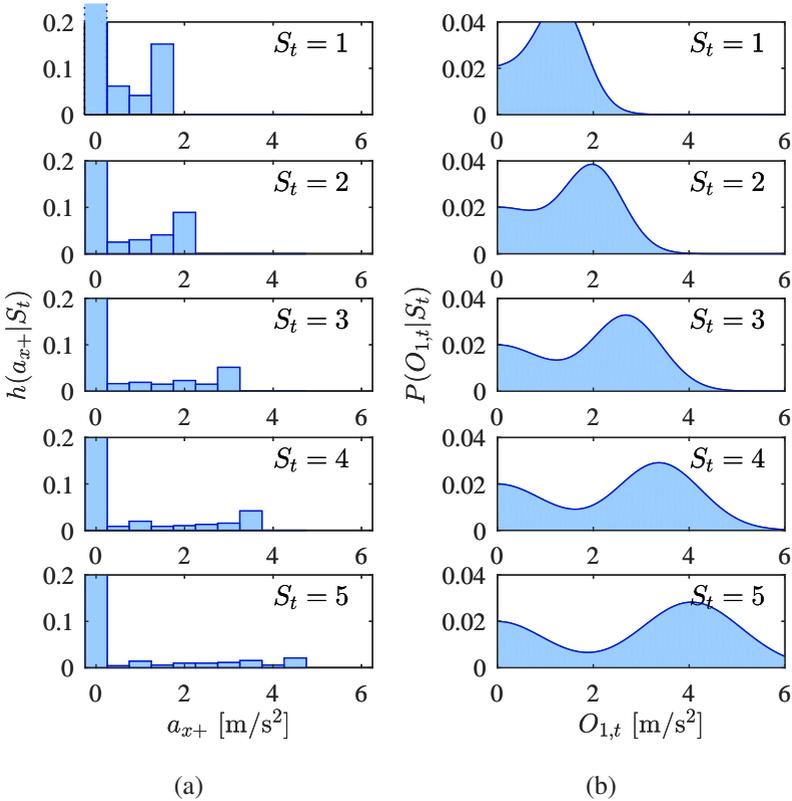


Abb. 3.20: (a) Relative Häufigkeitsverteilung $h(a_{x+}|S_t)$ der positiven Längsbeschleunigungen a_{x+} für die unterschiedlichen Fahrerwunschwundynamik-Zustände $S_t = 1..5$. Der Bereich $a_{x+} \approx 0$ ist nicht vollständig abgebildet. (b) Gewähltes Beobachtungsmodell $P(O_{1,t}|S_t)$ für die Beobachtung $O_{1,t}$ für die unterschiedlichen Fahrerwunschwundynamik-Zustände.

und p_{ij} die Übergangswahrscheinlichkeit $P(S_{t+1} = j|S_t = i)$. Für die Wahrscheinlichkeit $\pi_t(i)$ des Zustands i zum Zeitpunkt t gilt dann:

$$\pi_t(i) = P(S_t = i|O_{1:T}) = \frac{\alpha_t(i)\beta_t(i)}{\sum_{j=1}^K \alpha_t(j)\beta_t(j)}, \quad (3.49)$$

mit

$$\alpha_t(j) = \sum_{i=1}^K \alpha_{t-1}(i) \cdot p_{ij} \cdot P(O_t | S_t = j), \forall t > 1$$

$$\beta_t(i) = \sum_{j=1}^K \beta_{t+1}(j) \cdot p_{ij} \cdot P(O_{t+1} | S_{t+1} = j), \forall t < T$$
(3.50)

wobei

$$\alpha_1(i) = \pi_1(i) \cdot P(O_1 | S_1 = j), \forall i \in [1, K]$$

$$\beta_T(i) = 1, \forall i \in [1, K].$$
(3.51)

(siehe z.B. (Rab89))

Für die numerische Umsetzung der forward-backward Zerlegung müssen die Größen α_t und β_t normiert werden, da diese sehr kleine Werte annehmen (Potenzierung kleiner Wahrscheinlichkeitswerte) und dadurch numerische Ungenauigkeiten entstehen (vgl. (Rab89, CMR05)).

Zur Verifizierung des Beobachtungsmodells werden die fünf simulierten Beispielverläufe \underline{y} verwendet. Die Übergangsmatrix M wurde zur Bestimmung der Übergangswahrscheinlichkeiten zunächst entsprechend Gl. (3.31) angenommen. Abb. 3.21 zeigt die mittels forward-backward Zerlegung bestimmten Wahrscheinlichkeiten π_t für die fünf Durchläufe. Es werden zwar in Einzelsituationen die Zustände korrekt identifiziert, sehr häufig ist jedoch der Zustand $S_t = 1$ der wahrscheinlichste Zustand in allen Fahrten. Tabelle 3.3 zeigt die mittlere Wahrscheinlichkeit $\bar{P}(S_t = S_{ref})$ mit der der tatsächliche Zustand S_{ref} identifiziert wurde. Für die Fahrten mit $S_{ref} > 1$ liegt diese bei unter 0.20.

Tabelle 3.3: Mittlere Wahrscheinlichkeit $\bar{P}(S_t = S_{ref})$ mit der der tatsächliche Zustand S_{ref} für S_t identifiziert wurde.

S_{ref}	1	2	3	4	5
$\bar{P}(S_t = S_{ref})$	0.99	0.13	0.20	0.10	0.14

Dieses Beispiel verdeutlicht, dass nicht alle Beobachtungen O_t als Ausgabe eines Zustands (sog. Emission) betrachtet werden können, da die Beobachtungen nur in Situationen mit vorhandener Quer- oder Längsdynamik mit der Fahrerwunschdynamik korrelieren. Die herkömmliche Formulierung eines HMM

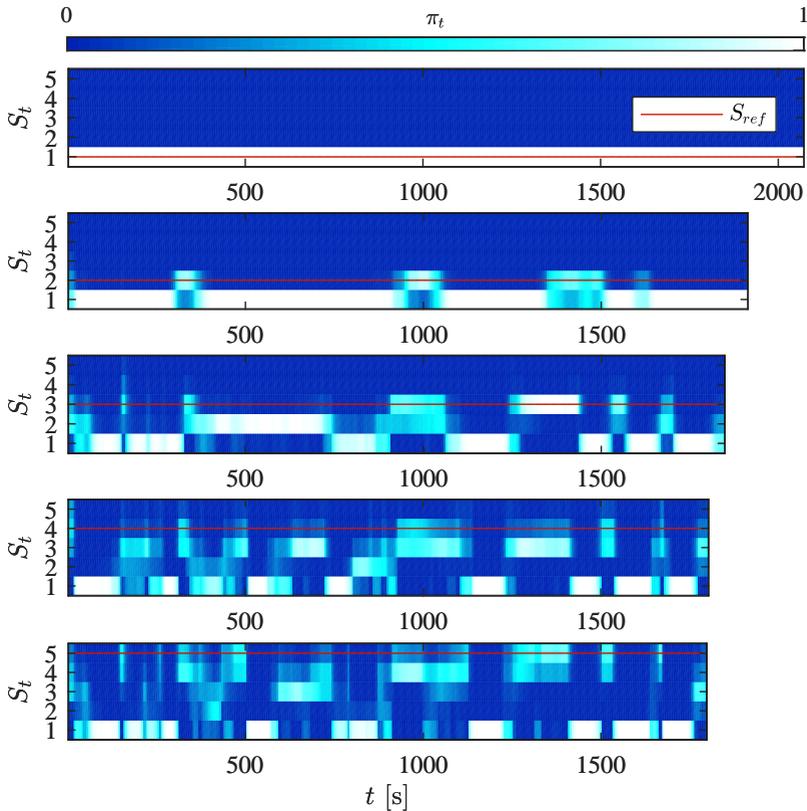


Abb. 3.21: Zustandswahrscheinlichkeiten π_t der Markov-Zustände S_t für den Zeitpunkt t und tatsächlicher Zustand S_{ref} für die fünf simulierten Fahrten. Da für die Simulationen Weggleichheit gilt, ist die Zeitdauer bei dynamischerem Fahrerverhalten ($S_{ref} = 5$) entsprechend kürzer ($S_{ref} = 1$).

bedingt aber diese Beziehung zwischen Beobachtung und Zustand. Um diese Beziehung aufzulösen und das Beobachtungsmodell entsprechend anzupassen, kann das HMM um eine Emissionswahrscheinlichkeit $P_E(O_{i,t})$ erweitert werden (FHFG17). $P_E(O_{i,t})$ stellt dabei die Wahrscheinlichkeit dar, dass $O_{i,t}$ eine Emission des Zustands S_t ist und somit vom Zustand S_t abhängt. Ist $O_{i,t}$ keine Emission, ist die Beobachtung vom Zustand unabhängig und somit für alle

Zustände gleich wahrscheinlich¹⁰. Für die modifizierten Beobachtungswahrscheinlichkeiten gilt dann

$$P^*(O_{i,t}|S_t) = P_E(O_{i,t})P(O_{i,t}|S_t) + (1 - P_E(O_{i,t})), \forall i \in [1, 3], \quad (3.52)$$

und für die kombinierte Beobachtungswahrscheinlichkeit entsprechend

$$P^*(O_t|S_t) = P^*(O_{1,t}|S_t) \cdot P^*(O_{2,t}|S_t) \cdot P^*(O_{3,t}|S_t) \text{ .(FHFG17)} \quad (3.53)$$

Die Emissionswahrscheinlichkeiten werden so definiert, dass sie gegen den Wert 1 streben, wenn eine entsprechende Dynamik vorhanden ist bzw. vorhanden sein sollte. Für die längsdynamischen Beobachtungen $O_{1,t}$ und $O_{2,t}$ (Beschleunigung und Verzögerung) wird die Emissionswahrscheinlichkeit daher abhängig von der Geschwindigkeitsdifferenz in einem Zeitfenster $c_{t,\Gamma} \cdot \Delta t$ gewählt. Für die Querdynamik ($O_{3,t}$) wird die Emissionswahrscheinlichkeit P_E abhängig von der bei Geschwindigkeit v_{lim} zu erwartenden Querbeschleunigung bei gegebener Kurvenkrümmung κ definiert. Die Berechnung von $P_E(O_{i,t})$ erfolgt dementsprechend nach

$$\begin{aligned} P_E(O_{1,t}) &= \max\left(\frac{\Delta v}{\Delta v_{ref}}, \frac{O_{1,t}}{a_{x+,ref}}\right) \\ P_E(O_{2,t}) &= \max\left(\frac{\Delta v}{-\Delta v_{ref}}, \frac{O_{2,t}}{a_{x-,ref}}\right) \\ P_E(O_{3,t}) &= \max\left(\frac{v_{lim}^2 \cdot \kappa}{a_{y,ref}}, \frac{O_{3,t}}{a_{y,ref}}\right), \\ \text{u.B.v. } P_E(O_{i,t}) &\in [0, 1] \forall i. \text{ (Vgl. (FHFG17))} \end{aligned} \quad (3.54)$$

Abb. 3.22 zeigt die entsprechenden Zustandswahrscheinlichkeiten π_t mit der modifizierten Beobachtungswahrscheinlichkeit nach Gl. (3.53) für geeignete,

¹⁰ Für den Fall, dass die Beobachtung $O_{i,t}$ keine Emission eines Zustands ist, gilt nach Gleichung 3.52 $P_E(O_{i,t}) = 1$. In Folge ist die Beobachtungswahrscheinlichkeit $P^*(O_{i,t}|S_t) = 1$ für jeden Zustand S_t . Eine Beobachtungswahrscheinlichkeit $P^*(O_{i,t}|S_t) = 1$ für alle Zustände führt dazu, dass die Beobachtung $O_{i,t}$ keinen Einfluss auf die Wahrscheinlichkeit eines Zustandsverlaufs hat (siehe Gleichung 3.53) und somit neutral in die Ermittlung der Zustandswahrscheinlichkeiten eingeht.

empirisch ermittelte Referenzgrößen ($\Delta v_{ref}, a_{x+,ref}, a_{x-,ref}, a_{y,ref}$). In Tabelle 3.4 ist die entsprechende mittlere Wahrscheinlichkeit für die Identifikation des korrekten Zustands $S_t = S_{ref}$ aufgeführt. Mit der Erweiterung um die Emissionswahrscheinlichkeit ermittelt das HMM den wahrscheinlichsten Fahrerwunschdynamik-Zustand korrekt für alle Beispielprofile. Die Schärfe der Zustandswahrscheinlichkeitsverteilung hängt dabei von der Ausprägung der Situation ab. In kurvigen Abschnitten mit zahlreichen Beschleunigungen sind die Zustandswahrscheinlichkeiten entsprechend schärfer abgetrennt als in Abschnitten ohne eindeutige Fahrerwunschdynamik-Indikatoren.

Tabelle 3.4: Mittlere Wahrscheinlichkeit $\bar{P}(S_t = S_{ref})$ mit der der tatsächliche Zustand S_{ref} für S_t identifiziert wurde beim Einsatz der modifizierten Beobachtungswahrscheinlichkeit $P^*(O_t|S_t)$.

S_{ref}	1	2	3	4	5
$\bar{P}(S_t = S_{ref})$	0.84	0.79	0.69	0.57	0.77

Die Parameter des HMM, folgend Θ bezeichnet, sind die Zustandsübergangswahrscheinlichkeiten $P(S_{t+1} = j|S_t = i)$ bzw. die Matrix der Übergangswahrscheinlichkeiten M und das Beobachtungsmodell $P(O_t|S_t)$. Da das Beobachtungsmodell in diesem Fall eine vorgegebene Beschreibung der Zustände und ihrer Bedeutung ist, wird dieses nicht mit den üblichen Verfahren zur Parameterschätzung adaptiert, sondern wird im Folgenden wie hergeleitet verwendet.¹¹

Für die Herleitung des Beobachtungsmodells wurde die Übergangsmatrix M bisher als gegebene, symmetrische Matrix (Annahme: alle Zustände treten gleich häufig auf) angenommen. Für die Schätzung der Übergangswahrscheinlichkeiten p_{ij} werden die Zustandswahrscheinlichkeiten π_i benötigt. Für die

¹¹ Im Allgemeinen Fall sind die Zustände eines HMM abstrakt, d.h. ihnen ist keine konkrete, vorgeschriebene Bedeutung zugewiesen. Die Zustände werden in einem solchen Fall verwendet um das Verhalten von Beobachtungsketten zu modellieren, wobei die Zusammensetzung des Systems (innere Zustände) nicht bekannt ist. Durch die Maximierung der Beobachtungswahrscheinlichkeit einer realen Beobachtungskette durch Adaption des Modellparameter, wird versucht eine möglichst gute Abbildung des realen Verhaltens der Beobachtungskette zu erzielen. Da die Bedeutung der Zustände im Kontext dieser Arbeit vorgeschrieben ist, darf das Beobachtungsmodell nicht durch z.B. Expectation-Maximization adaptiert werden. Das HMM würde ansonsten im Trainingsprozess die Bedeutung der Zustände modifizieren, sodass z.B. ein Zustand der Fahrsituation „Geradeaus Fahrt“entspricht, während ein anderer „Kurvenfahrt“repräsentiert.

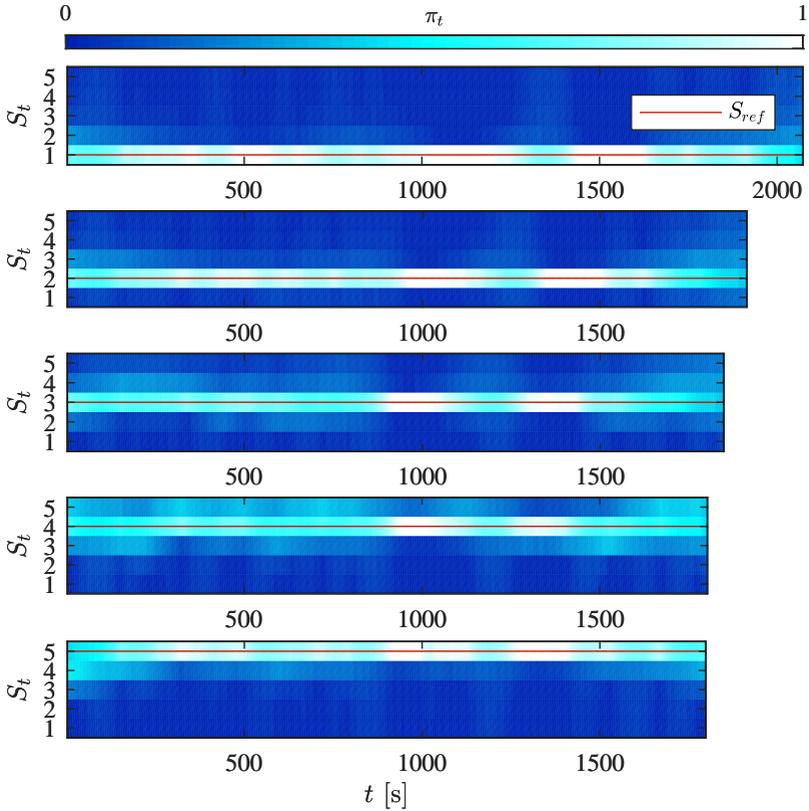


Abb. 3.22: Zustandswahrscheinlichkeiten π_t der Markov-Zustände S_i für den Zeitpunkt t und tatsächlicher Zustand S_{ref} für die fünf simulierten Fahrten. Zur Ermittlung von π_t wurden hier die modifizierten Beobachtungswahrscheinlichkeit $P^*(O_t|S_i)$ verwendet.

Ermittlung dieser Zustandswahrscheinlichkeiten werden aber wiederum die Übergangswahrscheinlichkeiten p_{ij} benötigt. Die Parameteridentifikation eines HMM wird daher auch als Maximum-Likelihood-Schätzung mit unvollständigen Daten bezeichnet. Ein geeignetes Verfahren zur Schätzung der HMM-Parameter ist die Expectation-Maximization-Methode (EM). EM ist eine iterative Methode, wobei im „Expectation“ Schritt die Erwartungswerte (z.B. Zustandswahrscheinlichkeiten mittels forward-backward-Zerlegung) basierend

auf einer Schätzung der Parameter Θ ermittelt werden. Im „Maximization“ Schritt wird basierend auf den Erwartungswerten eine ML-Schätzung der Parameter Θ ermittelt. Für HMM wird der EM-Algorithmus üblicherweise auch als Baum-Welch-Algorithmus bezeichnet. Für eine ausführliche Beschreibung des Baum-Welch-Algorithmus siehe (BPSW70, DL77, RJ86, Rab89, Bil98, Gha01, CMR05).

Sowohl die Forward-Backward-Zerlegung als auch der Baum-Welch-Algorithmus erfordern dabei das Vorliegen einer Zeitreihe für O_t . Diese Algorithmen sind damit nur bedingt für den echtzeitfähigen Online-Einsatz geeignet, da sie keine rekursive Formulierung ermöglichen. Eine echtzeitfähige Online-Schätzung ist aber wichtig um die Parameter des Fahrermodells während einer Fahrt direkt adaptieren zu können. An dieser Stelle wird der Ansatz nach (Cap11) vorgestellt:

Die übliche (offline) Vorgehensweise des EM-Algorithmus in der k -ten Iteration ist die Berechnung des Erwartungswerts einer suffizienten Statistik $s(S_{t-1}, S_t, O_t)$ mit

$$S_{n,k+1} = \frac{1}{n} \mathbb{E} \left[\sum_{t=2}^n s(S_{t-1}, S_t, O_t) \middle| O_{1:n} \right] \quad (3.55)$$

und die anschließende ML-Schätzung der Parameter

$$\Theta_{k+1} = \bar{\Theta}(S_{k+1}), \quad (3.56)$$

unter der Annahme, dass die Funktion $\bar{\Theta}(S)$ den Maximum-Likelihood-Schätzwert basierend auf der vollständigen Statistik S liefert. Gegeben seien nun

$$\pi_n(i) = P(S_t = i | O_{1:n}) \quad (3.57)$$

und die Hilfsgröße

$$\rho_n(i) = \frac{1}{n} \mathbb{E} \left[\sum_{t=2}^n s(S_{t-1}, S_t, O_t) \middle| O_{1:n}, S_n = i \right]. \quad (3.58)$$

Mit

$$\sum_i \pi_n(i) \rho_n(i) = \frac{1}{n} \mathbb{E} \left[\sum_{t=2}^n s(S_{t-1}, S_t, O_t) \middle| O_{1:n} \right] = S_n \quad (3.59)$$

ergibt sich dann die gesuchte Statistik des (offline) EM-Algorithmus. Der Vorteil dieser Zerlegung ist die Möglichkeit der rekursiven Aktualisierung der Größen nach folgender Vorschrift:

Initialisierung:

$$\pi_1(i) = \frac{\pi_0(i) \cdot P(O_1|S_1 = i)}{\sum_j \pi_0(j) \cdot P(O_1|S_1 = j)} \quad (3.60)$$

$$\rho_1(i) = 0,$$

wobei π_0 eine initiale Annahme für die Ausgangsverteilung der Zustände ist.

Rekursion: $\forall i$

$$\pi_{n+1}(i) = \frac{\sum_j \pi_n(j) \cdot P(S_{n+1} = i|S_n = j) \cdot P(S_{n+1} = i|O_{n+1})}{\sum_j \sum_k \pi_n(j) \cdot P(S_{n+1} = k|S_n = j) \cdot P(S_{n+1} = k|O_{n+1})}, \quad (3.61a)$$

$$\rho_{n+1}(i) = \sum_j \left(\frac{1}{n+1} s(j, i, O_{n+1}) + \frac{n}{n+1} \rho_n(j) \right) r_{n+1}(j|i), \quad (3.61b)$$

mit der retrospektiven Wahrscheinlichkeit

$$\begin{aligned} r_{n+1}(j|i) &= P(S_n = j|S_{n+1} = i, O_{0:n}) \\ &= \frac{\pi_n(j) P(S_{n+1} = i|S_n = j)}{\sum_k \pi_n(k) P(S_{n+1} = i|S_n = k)}. \end{aligned} \quad (3.62)$$

Um numerisch zuverlässiges Verhalten zu garantieren, wird der „Maximisation“-Schritt erst ab einer Mindestanzahl an Beobachtungen durchgeführt. Daher gilt für den ML-Schätzwert der Online-Variante des EM:

$$\hat{\Theta}_{n+1} = \begin{cases} \hat{\Theta}(\sum_i \pi_n(i) \rho_n(i)) & \text{falls } n \geq n_{min} \\ \hat{\Theta}_n & \text{sonst} \end{cases}. \quad (3.63)$$

Für die notwendigen Statistiken $s(S_{t-1}, S_t, O_t)$ zur Schätzung der Übergangsmatrix sei auf (Cap11) verwiesen. Man beachte, dass Gl. (3.61b) die üblichen rekursiven Gewichtungen $\frac{1}{n+1}$ und $\frac{n}{n+1}$ enthält (vgl. Gl. (3.37)). Zur Erhaltung der Anpassungsfähigkeit bei zeitveränderlichem Verhalten wird auch hier die Begrenzung der Gewichtungen auf $\frac{1}{\lambda+1}$ und $\frac{\lambda}{\lambda+1}$ mit $\lambda = \min(n, n_{max})$

vorgenommen. Man beachte weiter, dass im Gegensatz zu den vorhergehend behandelnden Prozessparametern, bei Modellen mit unvollständigen Daten die Schätzwerte der rekursiven und nicht-rekursiven Verfahrensweise nicht vollkommen identisch sind. Das rekursive Verfahren wird im Folgenden als Online-EM bezeichnet.

Für die Verifizierung der Schätzung der Übergangsmatrix M werden erneut virtuelle Testfahrten erzeugt. Dabei werden drei Simulationen durchgeführt, die beispielhaften ruhigen, durchschnittlichen und sportlichen Fahrern entsprechen. Die zugehörigen Matrizen M_1 , M_2 und M_3 sowie deren stationäre Verteilung π_∞ (Aufenthaltshäufigkeiten der Zustände für $t \rightarrow \infty$) sind in Anhang A.7 aufgeführt. Als initiale Schätzung \hat{M}_0 wird die symmetrische Matrix

$$M = [p_{ij}]_{5 \times 5},$$
$$p_{ij} = \begin{cases} 0.9 & \text{falls } i = j \\ 0.025 & \text{sonst} \end{cases} \quad (3.64)$$

gewählt.

Beispielhaft sind in Abb. 3.23 die identifizierten Zustandswahrscheinlichkeiten für die Testreihe mit dem durchschnittlichen Fahrer (M_2) und der tatsächliche Dynamikzustand S_{ref} dargestellt. Entsprechend der Übergangsmatrix ist der häufigste Zustand der mittlere Zustand $S_t = 3$. Sowohl das offline, als auch das rekursive Verfahren ermitteln diesen weitgehend zutreffend. Ebenso werden die meisten dynamischen Wechsel des Zustands S_{ref} erfasst. Einige der Zustandswechsel können vor allem in der zweiten Hälfte der Fahrt nicht erfasst werden (z.B. $t \approx 1200$ s). Dies ist auf die mangelnde Beobachtbarkeit bzw. fehlende Abbildung der gewünschten bzw. vom Fahrer tolerierten Fahrdynamik in den Messgrößen (z.B. Konstantfahrt ohne Kurven) zurückzuführen. Abb. 3.24 zeigt die gefahrene Geschwindigkeit und Längs- und Querschleunigungen (betragsmäßig) sowie die theoretischen Grenzwerte der Beschleunigungen durch den Fahrerwunschdynamik-Zustand S_{ref} für den betreffenden Zeitausschnitt. Die Darstellung zeigt, dass manche Wechsel des Fahrerzustandes nicht in den Messgrößen sichtbar werden, da sie in einer solchen Konstantfahrphasen auftreten.

Die Schätzwerte der Übergangsmatrix sind in Abb. 3.25 dargestellt. Die geschätzten Übergangsmatrizen weisen die gleiche Charakteristiken auf wie die

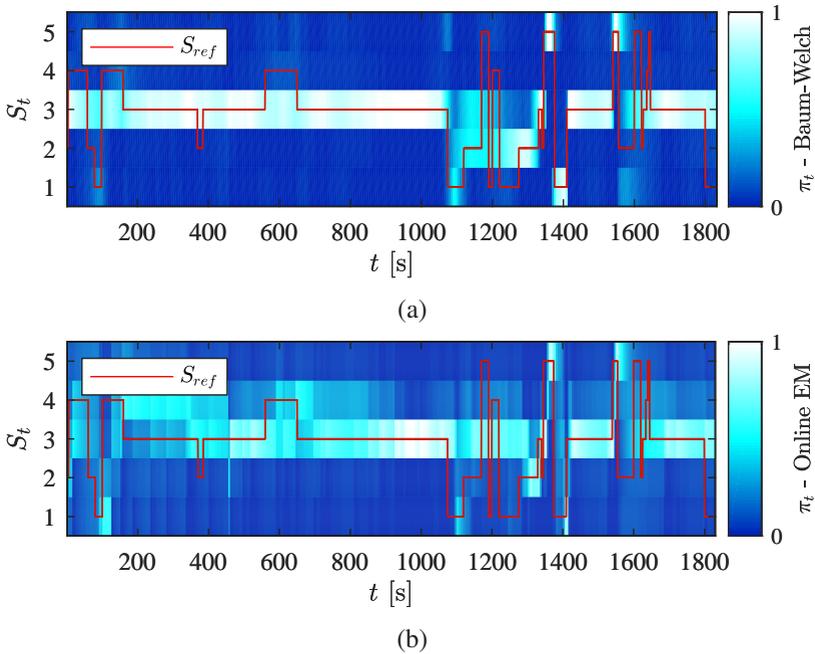


Abb. 3.23: Zustandswahrscheinlichkeiten π_t zum Zeitpunkt t und echter Zustand der Fahrerwunschdynamik $S_{ref}(t)$ für Testdaten erzeugt mit der Beispiel-Zustandsübergangsmatrix M_2 . Ermittelt mit einer Schätzung der Zustandsübergangsmatrix \hat{M} nach fünf Iterationen des Baum-Welch-Algorithmus (a) und rekursiv mit Online EM (b).

zugrundeliegende Matrix M_2 (a) mit geringfügigen Unterschieden zwischen der Baum-Welch-Schätzung (b) und der Online-EM-Schätzung (c). Die Schätzwerte und Zustandswahrscheinlichkeiten für die übrigen Fahrertypen sind in Anhang A.7 aufgeführt.

Die Beispiele zeigen, dass die Parameterschätzungen mittels Baum-Welch-Algorithmus und Online-EM vergleichbare Resultate liefern und die rekursive Variante keine relevanten Einschränkungen hinsichtlich der Schätzgenauigkeit im Vergleich zur Offline-Berechnung hat. Der aktuelle Zustand sowie die Charakteristik der Übergangsmatrix können – die Beobachtbarkeit vorausgesetzt – sowohl mittels Baum-Welch als auch mittels Online-EM mit hoher Zuverlässigkeit ermittelt werden.

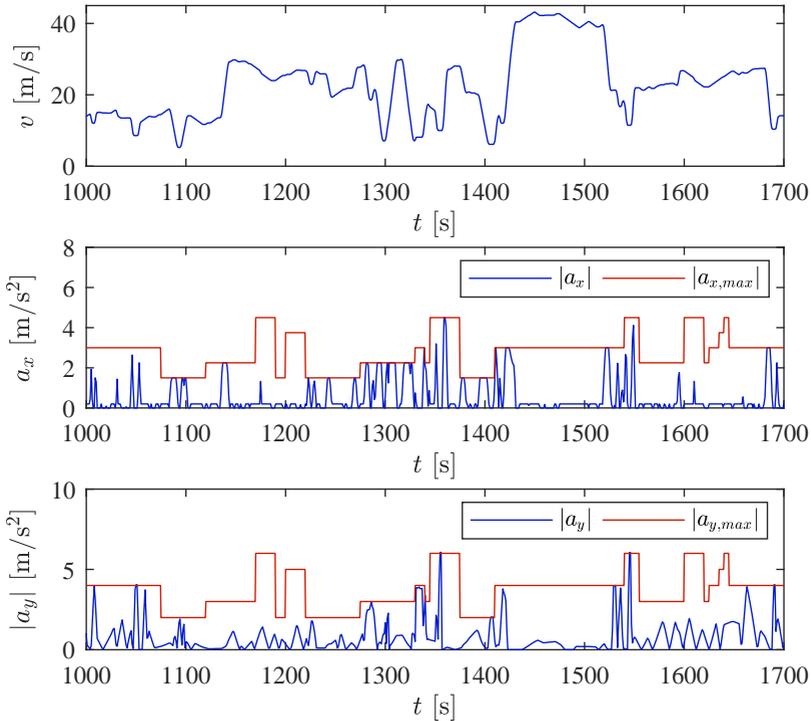


Abb. 3.24: Geschwindigkeit v , betragsmäßige Längsbeschleunigung a_x und betragsmäßige Querbeschleunigung a_y sowie die zugehörigen theoretischen Grenzwerte $a_{x,max}$ und $a_{y,max}$ des zugehörigen Fahrerwunschdynamik-Zustands $S_{ref}(t)$ zum Zeitpunkt t .

Zusammenfassend zeigen die simulativen Testfahrten, dass die Identifikation der stochastischen Prozessparameter (unter Ausnahme von ϕ) mit rekursiven Verfahren möglich ist. Einschränkungen bezüglich der Schätzgenauigkeit bestehen hauptsächlich durch eingeschränkte Beobachtbarkeit der zugrundeliegenden Zielgrößen. Für den Autokorrelationsparameter ϕ muss eine geeignete Annahme getroffen werden, da die eingeschränkte Beobachtbarkeit hier zu einer unzureichenden Schätzgenauigkeit führt.

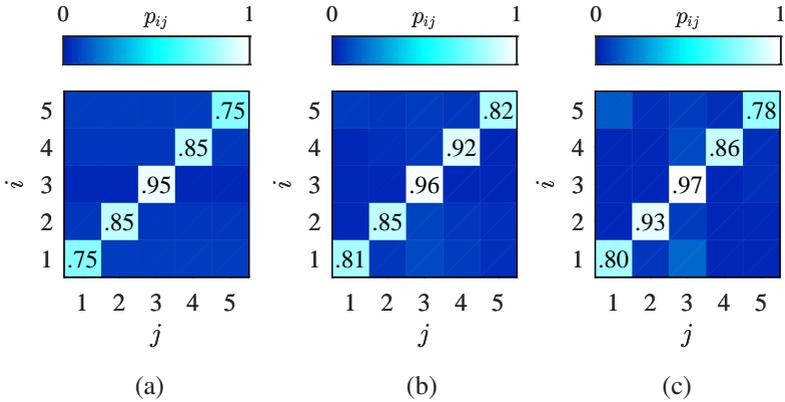


Abb. 3.25: Referenz-Zustandsübergangsmatrix M_2 (a) und die Schätzungen \hat{M} nach fünf Iterationen des Baum-Welch-Algorithmus (b) und rekursiv mit Online-EM (c). Übergangswahrscheinlichkeiten $p_{ij} = P(S_{t+1} = j | S_t = i)$.

3.6.3 Ergebnisse der Testfahrten

Nachdem die Parameterschätzung mit simulativen Daten verifiziert wurde, werden in diesem Abschnitt die Prozessparameter der Realfahrten analysiert. Die Prozessparameter werden mit den vorherig beschriebenen rekursiven Verfahren ermittelt.

Abb. 3.26(a) zeigt die geschätzten Parameter des Geschwindigkeitsprozesses. Mit wenigen Ausnahmen bewegt sich die mittlere Geschwindigkeitsabweichung μ_Δ in einem engen Bereich um 0 m/s mit einem Median von -0.26 m/s. Der Median der Streuung der Geschwindigkeitsabweichung σ_Δ liegt bei 2.77 m/s. Die Streuung σ_ϵ liegt etwas höher mit einem Median von 4.03 m/s. Der Autokorrelationsparameter ϕ wurde entsprechend der, in einem späteren Abschnitt ermittelten, Annahme ϕ_c gewählt (siehe hierzu Abschnitt 3.8.2). Abb. 3.26(b) zeigt die stationäre Verteilung π_∞ der Fahrerwunschdynamik-Zustände S^i für alle Fahrer, entsprechend der identifizierten Übergangsmatrizen \hat{M} . Die stationäre Verteilung π_∞ entspricht der erwarteten Häufigkeitsverteilung der Zustände über einen längeren Zeitraum. Diese Verteilungen zeigen hier unterschiedliche ermittelte Charakteristiken für die Fahrer. Während für einige

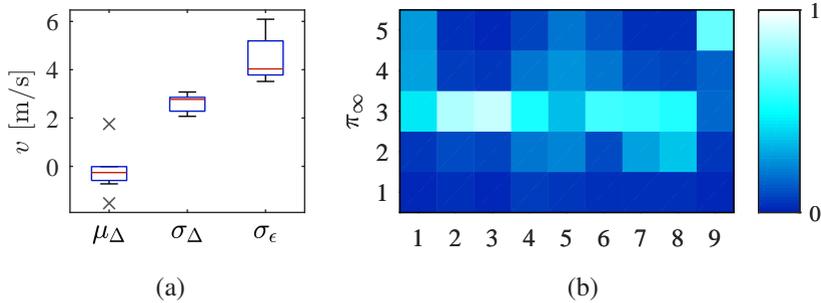


Abb. 3.26: Rekursiv identifizierte Prozessparameter am Ende einer Testfahrt für alle neun Testfahrten: Parameter μ_{Δ} , σ_{Δ} , σ_{ϵ} des Geschwindigkeitsverhaltens (a) und die erwarteten mittleren Häufigkeiten π_{∞} der Fahrerwunschdynamik-Zustände (stationäre Zustandsverteilungen des HMM) (b).

Fahrer durchgängig moderate (z.B. Fahrer 2 und 3) oder dynamische (Fahrer 9) Fahrerwunschdynamik-Zustände identifiziert werden, treten bei anderen Fahrten eine große Bandbreite von Dynamikzuständen auf (z.B. Fahrer 4 und 5). Dies verdeutlicht, dass mit zeitlichen Änderungen im Fahrerverhalten hinsichtlich der Wunschdynamik zu rechnen ist.

Zusammenfassend zeigt sich ein ähnliches mittleres Verhalten der Fahrer hinsichtlich der Geschwindigkeit, wobei bei allen Fahrern eine signifikante Streuung vorliegt. Bezüglich des Fahrstils bzw. der Fahrerwunschdynamik zeigen die Fahrer ein sehr unterschiedliches Verhalten.

3.7 Erzeugung stochastischer Vorhersagen

Mit der in Abschnitt 3.5.1 f_T beschriebenen Transferfunktion und den geschätzten Parametern ϑ und $\hat{\theta}$ kann eine Vorhersage der Fahrzeugdynamik y gemacht werden:

$$\hat{y}_{\bar{t}+1} = f_T(\hat{y}_{\bar{t}}, s_{\bar{t}}, \gamma_{\bar{t}}, \mathcal{T}_{PSD}) .^{12} \quad (3.65)$$

Da die Parameter der Transferfunktion durch einen stochastischen Prozess $\gamma_{\bar{t}} \sim \Gamma(\hat{\theta})$ beschrieben werden, kann durch selbigen Prozess eine stochastische Vorhersage der Fahrzeugdynamik y erfolgen. Um diese Vorhersage zu berechnen muss die aus der Prozessbeschreibung folgende Verteilung im Parameterraum von γ mit der Transferfunktion in die resultierende Verteilung der Fahrzeugdynamik y transformiert werden.

Da die Transferfunktion eine nicht-lineare Funktion ist und die Unsicherheiten nicht aus rein additiven Gauß'schen Verteilungen bestehen, kann diese Transformation nicht analytisch durchgeführt werden. Um die resultierende Verteilung $\hat{Y}_{\bar{t}}$ zu berechnen, muss daher auf Monte-Carlo Verfahren zurückgegriffen werden.

3.7.1 Monte-Carlo-Sampling und -Approximation

Die Idee des Monte-Carlo-Sampling ist, Eigenschaften einer Größe von Interesse und ihrer Verteilungsfunktion durch das Ziehen zufälliger Samples zu ermitteln. Sei also

$$\hat{Y}_K = \{\hat{y}_1, \dots, \hat{y}_K\} \quad (3.66)$$

¹² Da im Folgenden zwischen dem fortlaufenden Zeitindex t und dem Zeitindex der Vorhersage bezogen auf den Zeitpunkt t unterschieden werden muss, wird \bar{t} als Zeitindex der Vorhersage verwendet. $\bar{t} = 10$ bezieht sich damit auf eine Vorhersage für den Zeitpunkt $t + \bar{t} = t + 10$ und $\bar{t} = 0$ ist der Zeitpunkt t selbst.

eine Menge von K Samples der Verteilung Y , dann kann \hat{Y}_K als Approximation für die Verteilung Y verwendet werden. Die Dichtefunktion kann als Summe von Delta-Distributionen

$$f_{Y_K}(y) = \sum_{k=1}^K p_k \cdot \delta_{\hat{y}_k}(y), \quad (3.67)$$

mit Partikeln der Masse p_k an den Position \hat{y}_k dargestellt werden. Im Normalfall sind die Partikel gleichgewichtet ($p_k = \frac{1}{K}$). Die kumulierte Dichtefunktion der Vorhersagegröße $y_k \in \mathbb{R}^1$ kann dann mit

$$F_{\hat{Y}_K}(y) = \sum_{k=1}^K p_k \cdot \mathbf{1}_{\hat{y}_k}(y), \quad (3.68)$$

$$\mathbf{1}_b(a) = \begin{cases} 1 & \text{falls } a \geq b \\ 0 & \text{sonst} \end{cases}$$

angegeben werden. Der Erwartungswert der Vorhersage bzw. einer Funktion der Vorhersage berechnet sich mit

$$\mathbb{E}(\hat{Y}_K) = \sum_{k=1}^K p_k \cdot \hat{y}_k, \quad (3.69)$$

$$\mathbb{E}(f(\hat{Y}_K)) = \sum_{k=1}^K p_k \cdot f(\hat{y}_k).$$

Da das Monte-Carlo-Sampling in diesem Fall zur Approximation einer analytisch nicht zu berechnenden Verteilung verwendet wird, wird auch von Monte-Carlo-Approximation gesprochen. Siehe beispielsweise (Lem09) für eine ausführliche Behandlung von Monte-Carlo-Sampling.

Berechnung der Monte-Carlo-Approximation:

Im Folgenden wird die Berechnung einer i -Schritte-Monte-Carlo-Vorhersage der Fahrzeugdynamik $\hat{Y}_{i,K}$ geschildert.

Zunächst werden K Samples für den Parametervektor γ_i gezogen. Dieses ziehen der Parameter-Samples wird alle $c_{i,\Gamma}$ Zeitschritte wiederholt. Dabei folgen die Parameter von γ der entsprechenden Prozessbeschreibung Γ aus Abschnitt 3.5.2.

Für die Zielgeschwindigkeit gilt (Sample-Index k in folgenden Gleichungen zur einfacheren Lesbarkeit vernachlässigt):

$$v_{Z,\bar{t}+1} = v_{\mu,\bar{t}+1} + v_{AR,\bar{t}+1} \quad (3.70)$$

mit

$$\begin{aligned} v_{AR,\bar{t}+1} &= (1 - \delta_{\bar{t}})(\hat{\phi}v_{AR,\bar{t}} + \varepsilon_{\bar{t}}), & \varepsilon_{\bar{t}} &\sim \mathcal{N}(0, \hat{\sigma}_{\varepsilon}^2) \\ v_{\mu,\bar{t}+1} &= \delta_{\bar{t}}\alpha_{\bar{t}} + (1 - \delta_{\bar{t}})v_{\mu,\bar{t}}, & \alpha_{\bar{t}} &\sim \hat{V}_Z \\ v_{\mu,0} &= v_{Z,t}, \quad v_{AR,0} = 0 \end{aligned} \quad (3.71)$$

mit $\delta_{\bar{t}}$ entsprechend Gl. (3.23). Der Fahrerwunschdynamik-Zustand $S_{\bar{t}}$ folgt der Markov-Ketten-Beschreibung mit

$$\begin{aligned} S_{\bar{t}+1} &\sim P(S_{\bar{t}+1}|S_{\bar{t}}), \\ S_0 &\sim \pi_t. \end{aligned} \quad (3.72)$$

Die Fahrerwunschdynamik-Parameter γ_d ergeben sich entsprechend aus dem Markov-Zustand mit

$$\gamma_{d,t+1} = \tilde{\gamma}_{d,S_{\bar{t}+1}}. \quad (3.73)$$

Siehe hierzu Tabelle 3.2.

Das Zielsegment s_{ID} wird entsprechend der Segmentwahrscheinlichkeiten gezogen, siehe hierzu Gl. (3.17) bzw. Gl. (3.18).

Mit dem so erhaltenen Vektor $\gamma_{t,k}$ können die resultierenden Samples $y_{\bar{t},k}$ der Fahrzeugdynamik berechnet werden. Dementsprechend formuliert sich die Berechnung der Vorhersage zu

$$\begin{aligned} \forall \bar{t} \in [0, T], \forall k \in [1, K] : \\ \hat{y}_{\bar{t}+1,k} &= f_T(\hat{y}_{\bar{t},k}, s_{\bar{t},k}, \gamma_{\bar{t}+1,k}, \mathcal{T}_{PSD}), \\ \gamma_{\bar{t}+1,k} &\begin{cases} \gamma_{\bar{t}+1,k} \sim \Gamma(\gamma_{\bar{t},k}, \hat{\theta}) & \text{falls } \bar{t} = k \cdot c_{t,\Gamma}, k \in \mathbb{N} \\ \gamma_{\bar{t}+1,k} = \gamma_{\bar{t},k} & \text{sonst} \end{cases}, \end{aligned} \quad (3.74)$$

mit $\hat{y}_{0,k}$ initialisiert auf den aktuellen Ist-Zustand der Fahrzeugdynamikgrößen

$$\hat{y}_{0,k} = y_t. \quad (3.75)$$

Abb. 3.27 zeigt eine beispielhafte Vorhersage $\hat{Y}_{\bar{t},K}$ für $K = 10$ für die Streckensituation entsprechend Abb. 3.3 und exemplarische Prozessparameter θ .

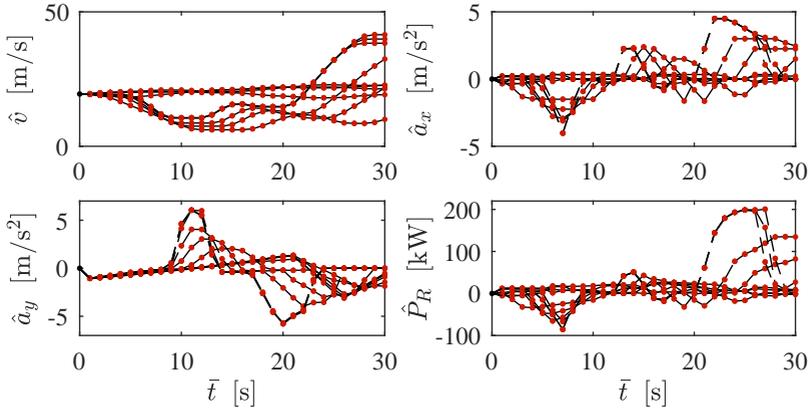


Abb. 3.27: Beispielhafte Monte-Carlo-Vorhersagen $\hat{Y}_{\bar{t},K}$ der Fahrzeugdynamikgrößen (Geschwindigkeit v , Längsbeschleunigung a_x , Querbeschleunigung a_y und Radleistung P_R) mit $K = 10$ Samples für einen Vorhersagezeithorizont T von 30 Sekunden.

Der benötigte Rechenaufwand zur Erzeugung der Vorhersage hängt dabei von der Anzahl an Samples K und dem Vorhersagehorizont T ab. Der Vorhersagehorizont T ist außerdem von der Länge des verfügbaren elektronischen Horizonts abhängig. Im Folgenden wird der Vorhersagehorizont $T = 30\text{s}$ gewählt, da dieser Horizont bei der gegebenen Datenlage in fast allen Fällen durch den elektronischen Horizont abgedeckt ist und als sinnvoller Kompromiss aus verfügbaren Daten und benötigtem Rechenaufwand betrachtet werden kann.

3.7.2 Konvergenz und Varianz

Der Vorteil einer Monte-Carlo-Approximation ist, dass die Verteilungen $\hat{Y}_{\bar{t}}$ für jede beliebige nicht-lineare Transformation sowie beliebige stochastische Prozesseinflüsse approximiert werden können. Nachteilig ist der offensichtlich von der Sample-Größe K abhängige Rechenaufwand sowie das nicht-deterministische Verhalten der Vorhersage. Daher stellt sich die Frage nach der

Genauigkeit der Approximation abhängig von der Anzahl an Samples K sowie des Zufallseinflusses durch das Monte-Carlo-Sampling. Diese Einflüsse sollen im Folgenden analysiert werden.

Die mit Monte-Carlo-Sampling approximierte Verteilung konvergiert fast sicher für $K \rightarrow \infty$ (Lem09). Die Anforderungen an geringen Rechenaufwand schränken den möglichen Wertebereich für K aber auf relativ kleine Werte ein (z.B. $K < 20$). Es ist somit zu untersuchen, wie groß die Diskrepanz zwischen aufeinander folgenden Vorhersagen bzw. einer Vorhersage und einer fast sicher konvergierten Verteilung ist. Für diese Untersuchungen wird zunächst ein Abstandsmaß für zwei Vorhersagen $\hat{Y}_{t,K}$ benötigt. Ein häufig verwendetes Abstandsmaß für zwei Wahrscheinlichkeitsverteilungen P und Q ist die Wasserstein-Distanz W_p der Ordnung p für die Metrik ρ

$$W_p(P, Q) = \sqrt[p]{\inf \mathbb{E} [\rho(\xi, \eta)^p]}, \quad (3.76)$$

wobei \inf^{13} über alle Permutationen möglicher Paare der Zufallsvariablen ξ und η mit Verteilungen P und Q ermittelt wird (Vil09). Für die euklidische Metrik und $x \in \mathbb{R}^1$ kann die Wasserstein-Distanz auch als Integral

$$W_p(P, Q) = \left(\int_{-\infty}^{\infty} |F(x) - G(x)|^p dx \right)^{\frac{1}{p}} \quad (3.77)$$

mit den Verteilungsfunktionen F und G der Verteilungen P und Q geschrieben werden (Val74). Die Wasserstein-Distanz wird in Computerwissenschaften auch als „Earth Mover’s Distance“ bezeichnet (vgl. (RT01)), da sie die Lösung des optimalen Transportproblems zur Verschiebung der Verteilung P in die Verteilung Q bzw. umgekehrt ist (Vil09). Eine Methode zur Berechnung von W_p für zwei Samplevorhersagen $\hat{Y}_{t,K}$ wird in Anhang A.8 beschrieben. Die Wasserstein-Distanz kann in der Einheit der Vorhersagegröße berichtet werden.

Zur Untersuchung der Diskrepanz zwischen unterschiedlichen Vorhersagen mit gleichen Parametern und des Konvergenzverhaltens der Monte-Carlo-Approximation für wachsende K wird eine Referenzvorhersage $\hat{Y}_{t,500}$ mit $K = 500$ Samples für die Beispielsituation aus Abb. 3.3 durchgeführt. Anschlie-

¹³ $\inf \triangleq$ Infimum: Größte untere Schranke.

End werden die Samplegröße variiert ($K \in [1, 100]$) und je 10 Vorhersagen bei konstanter Samplegröße berechnet. Da die Beispielsituation aus mehreren Routenoptionen mit Autobahn- und Landstraßenanteil besteht, wird hier eine große Varianz in der Verteilungsvorhersage erwartet. Diese Streckensituation eignet sich daher für Referenzuntersuchungen.

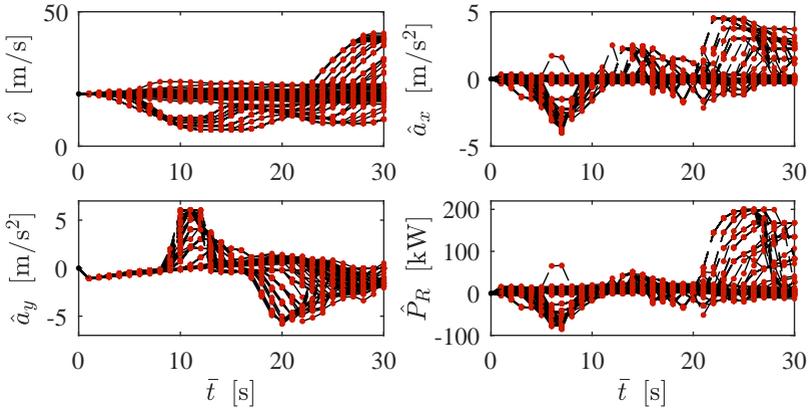


Abb. 3.28: Referenz-Vorhersage $\hat{Y}_{\bar{t},500}$ mit $K = 500$ Samples. Aus Gründen der Darstellbarkeit sind nur 100 Samples abgebildet.

Unter Wasserstein-Distanz wird im Folgenden zur einfacheren Referenzierung der Mittelwert der Wasserstein-Distanz über alle Vorhersagehorizonte ($\bar{t} \in [1, T]$) verstanden. Zur Bewertung der Konvergenz wird die Wasserstein-Distanz erster Ordnung von der Referenzvorhersage mit

$$W_{1,ref} = \frac{1}{T} \sum_{\bar{t}=1}^T W_1(\hat{Y}_{\bar{t},K}, \hat{Y}_{\bar{t},500}) \quad (3.78)$$

berechnet. Die Diskrepanz zwischen zwei Vorhersagen mit gleicher Samplegröße K wird durch die Wasserstein-Distanz der Vorhersagen untereinander mit

$$W_{1,K} = \frac{1}{T} \sum_{\bar{t}=1}^T W_1(\hat{Y}_{\bar{t},K}^{(i)}, \hat{Y}_{\bar{t},K}^{(j)}), \quad i \neq j \quad (3.79)$$

bewertet, wobei $\hat{Y}_{t,K}^{(i)}$ und $\hat{Y}_{t,K}^{(j)}$ zwei unterschiedliche Vorhersagen mit gleicher Sample-Größe sind. Für die Distanzen $W_{1,ref}$ und $W_{1,K}$ werden die Mittelwerte und Standardabweichungen über alle Vorhersagen einer Sample-Größe ausgewertet, folgend als $\mathbb{E}(\cdot)$ und $\sigma(\cdot)$ notiert.

Abb. 3.29 zeigt das Konvergenzverhalten (a) und die Distanz zwischen einzelnen Vorhersagen (b) beispielhaft für die Vorhersage der Geschwindigkeit. Der Abstand zur Referenzverteilung $W_{1,ref}$ verringert sich sukzessive mit

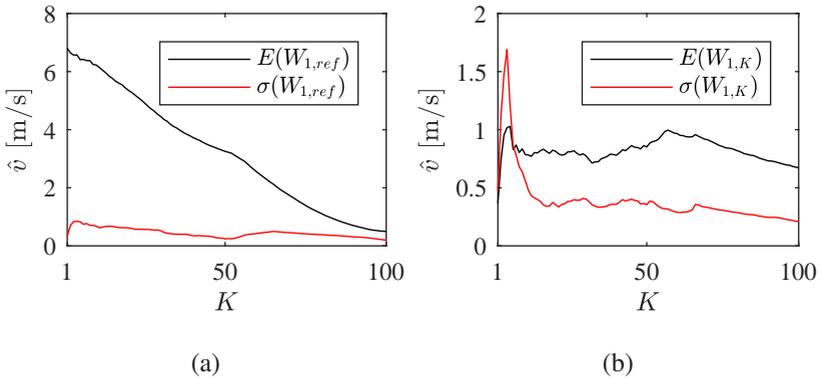


Abb. 3.29: Bewertung der Vorhersage \hat{v} der Geschwindigkeit abhängig von der Anzahl an Samples K . (a) Konvergenz: Mittelwert $E(W_{1,ref})$ und Standardabweichung $\sigma(W_{1,ref})$ der Wasserstein-Distanz von 10 Vorhersagen mit K Samples zur Referenzvorhersage mit 500 Samples. (b) Diskrepanz: Mittelwert und Standardabweichung der Wasserstein-Distanz zwischen den 10 Vorhersagen mit K Samples.

zunehmender Anzahl an Samples und verdeutlicht die Konvergenz für große Sample-Größen K . Der mittlere Abstand $\mathbb{E}(W_{1,ref})$ sinkt dabei von ca. 7 m/s bei $K = 1$ auf weniger als 1 m/s bei $K = 100$. Die Standardabweichung des Abstandes $\sigma(W_{1,ref})$ ist unabhängig von der Anzahl an Samples gering. Die mittlere Distanz $\mathbb{E}(W_{1,K})$ zwischen den Vorhersagen bei gleicher Sample-Größe ist unabhängig von der Sample-Größe K gering (kleiner 1 m/s). Diese Distanz weist dabei eine größere Streuung für $K < 10$ auf.

Im Mittel unterscheiden sich zwei Vorhersagen somit nur geringfügig und der Abstand zur Referenzverteilung sinkt mit wachsender Sample-Größe K . Für geringere Sample-Größen ($K < 10$) treten dabei größere Streuungen des

Abstands zwischen Vorhersagen bei gleicher Sample-Größe auf. Wird $K \geq 10$ gewählt, ist der Zufallseinfluss beim Erzeugen der Vorhersage somit vernachlässigbar gegenüber dem Abstand zur Referenzverteilung. Dieser nimmt für die Geschwindigkeitsvorhersagen linear mit zunehmender Anzahl an Samples ab. Die übrigen Vorhersagegrößen weisen vergleichbare Charakteristiken auf. Siehe hierzu Anhang A.9.

3.8 Validierung des Vorhersagemodells

In den vorhergehenden Abschnitten wurde das Schätzen von Prozessparametern und das Erzeugen von stochastischen Vorhersagen für das vorgeschlagene Vorhersagemodell behandelt. In diesem Abschnitt erfolgt die Validierung und Bewertung des Vorhersagemodells mit den realen Testfahrten (siehe hierzu auch Abschnitt 3.4).

3.8.1 Bewertungsgrößen

Bevor eine Analyse der Vorhersagegüte erfolgen kann, müssen geeignete Bewertungsgrößen definiert werden. Wie bereits in Abschnitt 2.3.2 diskutiert ist die Bewertung von Vorhersagen ein häufig unzureichend behandeltes Thema (siehe z.B. (Gne11)).

In den letzten Jahren hat sich in der Wissenschaft der Konsens gebildet, dass stochastische Vorhersagen hinsichtlich des Paradigmas „maximizing the sharpness [...] subject to calibration“ (GBR07, S. 243) bewertet werden sollten. Dabei bezieht sich Kalibrierung auf die statistische Konsistenz zwischen den Verteilungsvorhersagen und den Beobachtungen. Die Schärfe bezieht sich auf die Konzentration der Verteilungsvorhersage. Eine kombinierte Bewertung von *calibration* und *sharpness* kann durch *Proper Scoring Rules* erfolgen. Dabei wird die Vorhersageverteilung \hat{Y} basierend auf einer Realisierung y bewertet. Der Score einer Realisierung wird als $s(\hat{Y}, y)$ geschrieben. „Proper“ bezieht sich dabei auf die Eigenschaft, dass der Erwartungswert von $s(\hat{Y}, y)$ maximal wird, wenn y aus der Verteilung \hat{Y} stammt. Diese Bewertungsregeln erfordern „aufrichtige“ Vorhersagen, da sich sowohl eine Über- als auch eine Unterschätzung der Unsicherheit negativ auf die Bewertung auswirkt. (GBR07, GR07)

Eine häufig verwendete Bewertungsregel für Sample-Vorhersagen ist der continuous ranked probability score (*CRPS*). In seiner negativen Orientierung, definiert sich dieser mit der Verteilungsfunktion der Vorhersage als

$$CRPS(\hat{Y}, y) = \int_{-\infty}^{\infty} [F_{\hat{Y}}(x) - \mathbf{1}_y(x)]^2 dx, \quad (3.80)$$

$$\mathbf{1}_y(x) = \begin{cases} 1 & \text{falls } x \geq y \\ 0 & \text{sonst} \end{cases},$$

wobei $F_{\hat{Y}}$ die Verteilungsfunktion der Vorhersage \hat{Y} ist. ¹⁴ Eine alternative Darstellung des *CRPS* ist durch

$$CRPS(F, y) = \mathbb{E}(|X - x|) - \frac{1}{2} \mathbb{E}(|X - X'|), \quad (3.81)$$

gegeben, wobei X und X' unabhängig Realisierungen von Zufallsvariablen mit Verteilungsfunktion $F_{\hat{Y}}$ sind. (GR07)

Für eine Sample-Vorhersage $\hat{Y}_K = \{\hat{y}_k\}_{k \in [1, K]}$ mit Gewichtungen p_k und der Realisierung y ermittelt sich der *CRPS* mit

$$CRPS(\hat{Y}_K, y) = \sum_{k=1}^K p_k \cdot |\hat{y}_k - y| - \frac{1}{2} \sum_{k=1}^K \sum_{k'=1}^K p_k \cdot p_{k'} \cdot |\hat{y}_k - \hat{y}_{k'}|. \quad (3.82)$$

(GGBJ06)

In der angegebenen negativen Orientierung kann der *CRPS* in der Einheit der Vorhersagegröße angegeben werden und ist die Generalisierung des absoluten Fehlers auf Verteilungsvorhersagen. Für eine Punktvorhersage reduziert sich der mittlere *CRPS*, folgend als *MCRPS* bezeichnet, auf den mittleren absoluten Fehler (*MAE* - mean average error). Der *MCRPS* kann somit auch zum Vergleich von Punkt- und Verteilungsvorhersagen eingesetzt werden, da er für beide Vorhersagen gleichermaßen berechnet werden kann. (GR07)

¹⁴ Der Vergleich von Gl. (3.80) und Gl. (3.77) zeigt, dass der continuous ranked probability score verwandt mit der Wasserstein-Distanz 2. Ordnung zwischen der Vorhersage und der Punktrealisierung ist.

Der *CRPS* wird für einen Vorhersagehorizont \bar{t} als Mittelwert über alle Zeitpunkte einer Fahrt ($MCRPS_{\bar{t}}$) und als totaler Mittelwert über alle Vorhersagehorizonte ermittelt ($MCRPS$):

$$\begin{aligned} MCRPS_{\bar{t}} &= \frac{1}{|\{t\}|} \sum_t CRPS(F_{\hat{Y}_{t,K}}, y_{t+\bar{t}}), \\ MCRPS &= \frac{1}{|\{\bar{t}\}|} \sum_{\bar{t}} MCRPS_{\bar{t}}. \end{aligned} \tag{3.83}$$

Als zusätzliche Bewertungsgröße wird der Energy Score (*ES*) verwendet. Der Energy Score ist eine Generalisierung des *CRPS* und ist in ebenfalls negativer Orientierung als

$$ES(F, y) = \mathbb{E}(|X - x|^\beta) - \frac{1}{2} \mathbb{E}(|X - X'|^\beta) \tag{3.84}$$

mit $\beta \in (0, 2)$ definiert. Für den Grenzfall $\beta = 2$ ist diese Scoring Rule zwar nicht mehr streng „proper“, aber immernoch „proper“ und generalisiert den mittleren quadratischen Fehler (*MSE* - mean squared error) auf Verteilungen. (GR07)

Folgend wird der Energy Score für den Grenzfall $\beta = 2$ als Ergänzung zum *CRPS* verwendet. Die Berechnung kann in diesem Fall durch

$$ES(F_{\hat{Y}_K}, y) = \sum_{k=1}^K p_k \cdot |y_k - y|^2 - \frac{1}{2} \sum_{k=1}^K \sum_{k'=1}^K p_k \cdot p_{k'} \cdot |y_k - y_{k'}|^2 \tag{3.85}$$

erfolgen. Da der mittlere Energy Score (*MES*) für $\beta = 2$ als Generalisierung des *MSE* interpretiert werden kann, wird im Folgenden seine Wurzel (*RMES* - Root Mean Energy Score) entsprechend des *RMSE* (Root Mean Square Error) angegeben:

$$RMES = \sqrt{MES}. \tag{3.86}$$

Der *RMES* kann ebenfalls in der Einheit der Vorhersagegröße angegeben werden. Der *RMES* wird entsprechend für einen Vorhersagehorizont \bar{t} als

Mittelwert über alle Zeitpunkte einer Fahrt ($RMES_{\bar{t}}$) und als totaler Mittelwert über alle Vorhersagehorizonte ermittelt ($RMES$):

$$RMES_{\bar{t}} = \sqrt{\frac{1}{|\{\bar{t}\}|} \sum_{\bar{t}} ES(F_{\hat{Y}_{\bar{t},K}}, y_{t+\bar{t}})}, \quad (3.87)$$

$$RMES = \frac{1}{|\{\bar{t}\}|} \sum_{\bar{t}} RMES_{\bar{t}}.$$

Die Schärfe bzw. Konzentration der Vorhersagen kann zusätzlich über die Breite der zentralen Vorhersageintervalle analysiert werden. Hierfür wird die Breite B_p des zentralen Vorhersageintervalls p mit

$$B_p = F_{\hat{Y}}^{-1}\left(0.5 + \frac{p}{2}\right) - F_{\hat{Y}}^{-1}\left(0.5 - \frac{p}{2}\right) \quad (3.88)$$

ermittelt, wobei $F_{\hat{Y}}^{-1}$ die Inverse der Verteilungsfunktion der Vorhersage ist.

3.8.2 Einflussanalyse

Autoregressionsparameter ϕ

Wie in Abschnitt 3.6.2 beschrieben, kann die Autokorrelation ϕ des AR(1)-Modells der Zielgeschwindigkeit aufgrund der Charakteristik der Übertragungsfunktion nicht zuverlässig ermittelt werden. Um zu untersuchen, ob das zeitliche Verhalten eher einem korrelierten oder unkorrelierten Prozess folgt, werden Vorhersagen mit unterschiedlichen Annahmen für ϕ verglichen. Zur Analyse des Einflusses wird daher die Vorhersage mit einem festen Schätzwert ϕ_c der Autokorrelation ($\hat{\phi} = \phi_c$) mit der Vorhersage mit der CML-Schätzung $\hat{\phi} = \hat{\phi}_{CML}$ verglichen. Der feste Schätzwert ϕ_c wird zwischen 0 und 0.9 variiert. Die Route wird für die Berechnung der Vorhersagen als bekannt angenommen. Die Parameter $\hat{\theta}$ werden mit einem Durchlauf der Fahrt initialisiert. Es wird keine Begrenzung des Lernhorizonts vorgenommen (siehe hierzu auch Abschnitt 3.8.2). In einem zweiten Durchlauf werden die Vorhersagen berechnet und ausgewertet. Die Vorhersagen werden für die Vorhersagehorizonte $\bar{t} \in [2, 5, 10, 15, 20, 30]$ ausgewertet. Die Sample-Größe der Vorhersagen wird als $K = 10$ gewählt.

Abbildung 3.30 zeigt den *MCRPS* und *RMES* der Geschwindigkeit gemittelt über alle Fahrten und Zeithorizonte. Die mittlere Abweichung (*MCRPS*) und mittlere quadratische Abweichung (*RMES*) ist für die unkorrelierte Zeitreihe ($\phi_c = 0$) am geringsten. Die Fehlermaße steigen mit größerem ϕ_c geringfügig an. Bei Verwendung der CML-Schätzung $\hat{\phi}_{CML}$ zeigen sich ähnliche Fehlerwerte wie bei Annahme einer (festen) hohen Autokorrelation. Dies ist nicht verwunderlich, da die beobachtbare Zeitreihe immer zur Schätzung einer hohen Autokorrelation führt (siehe auch Abschnitt 3.6.2).

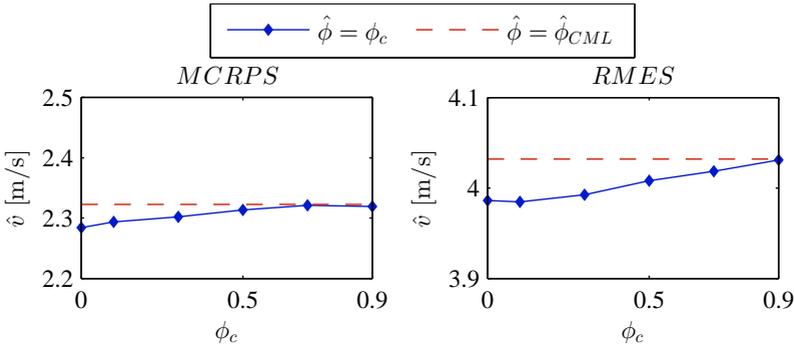


Abb. 3.30: Mittlere Abweichung (*MCRPS*) und mittlere quadratische Abweichung (*RMES*) der Geschwindigkeitsvorhersage \hat{v} über alle Fahrten für unterschiedliche Konstantwerte $\hat{\phi} = \phi_c$ (blau) und den CML-Schätzwert $\hat{\phi} = \phi_{CML}$ (rot).

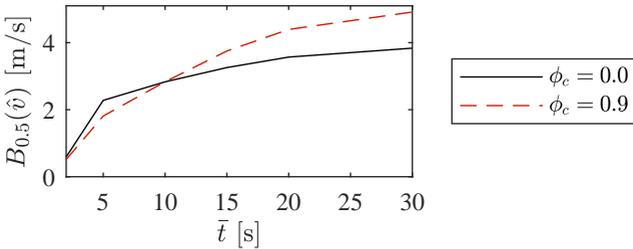


Abb. 3.31: Über alle Fahrten ermittelte mittlere Breite $B_{0,5}$ des 50%-Vorhersageintervalls der Geschwindigkeit v für den Vorhersagehorizont \bar{t} bei festen AR-Koeffizienten $\phi_c = 0$ und $\phi_c = 0,9$.

Der Unterschied in der Vorhersage zwischen einer korrelierten und unkorrelierten Zeitreihe lässt sich gut an der Entwicklung der Breite des 50%-Vorhersageintervalls über den Vorhersagehorizont darstellen. Wie Abb. 3.31 zeigt, nimmt für die unkorrelierte Vorhersage die Streuung schneller zu, bleibt aber für einen größeren Zeithorizont geringer als bei der korrelierten Zeitreihe. Entsprechend der Bewertungsgrößen folgen die realen Daten eher dem Verhalten der unkorrelierten Zeitreihe. Im Folgenden wird daher die konstante Annahme $\hat{\phi} = 0$ verwendet.

Lernhorizont

Ein weiterer Parameter des Vorhersagemodells, dessen Einfluss untersucht werden soll, ist der Lernhorizont der rekursiven Parameterschätzverfahren. Die rekursiven Schätzgrößen haben i. A. eine Form

$$\hat{\theta}_n(x_{1:n}) = \frac{\lambda - 1}{\lambda} \hat{\theta}_{n-1}(x_{1:n-1}) + \frac{1}{\lambda} x_n, \quad (3.89)$$

wobei θ_n die Schätzung des Parameters θ nach n Beobachtungen ist und x_n die n -te Beobachtung. Der Gewichtungparameter λ ist definiert durch

$$\lambda = \min(n, n_{max}) \quad (3.90)$$

mit dem n_{max} -schrittigen Lernhorizont. Der zeitliche Lernhorizont für die Prozessparameter ergibt sich dann mit der Zeitschrittkonstante $c_{t,\Gamma}$ und der Zeitdiskretisierung Δt zu

$$t_{lh} = n_{max} \cdot c_{t,\Gamma} \cdot \Delta t. \quad (3.91)$$

Um den Einfluss des Lernhorizonts zu bewerten, werden Vorhersagen mit unterschiedlicher Konfiguration durchgeführt. Dabei wird eine Testfahrt jeweils fünfmal wiederholt und die Vorhersagen der ersten und letzten Fahrt bewertet. Die Parameter werden mit den in Abschnitt 3.6.1 definierten Werten initialisiert. Dabei werden Lernhorizonte t_{lh} von 5 und 30 Minuten mit einem unbegrenzten Lernhorizont ($t_{lh} = \infty$) verglichen. Die Vorhersagen werden mit $K = 10$ Samples berechnet.

Abb. 3.32 zeigt die mittlere Performance der Vorhersagen im ersten und fünften Durchlauf einer Fahrt, normiert auf das Resultat ohne Beschränkung des Lernhorizonts im ersten Lauf. Erwartungsgemäß fallen die Bewertungsgrößen

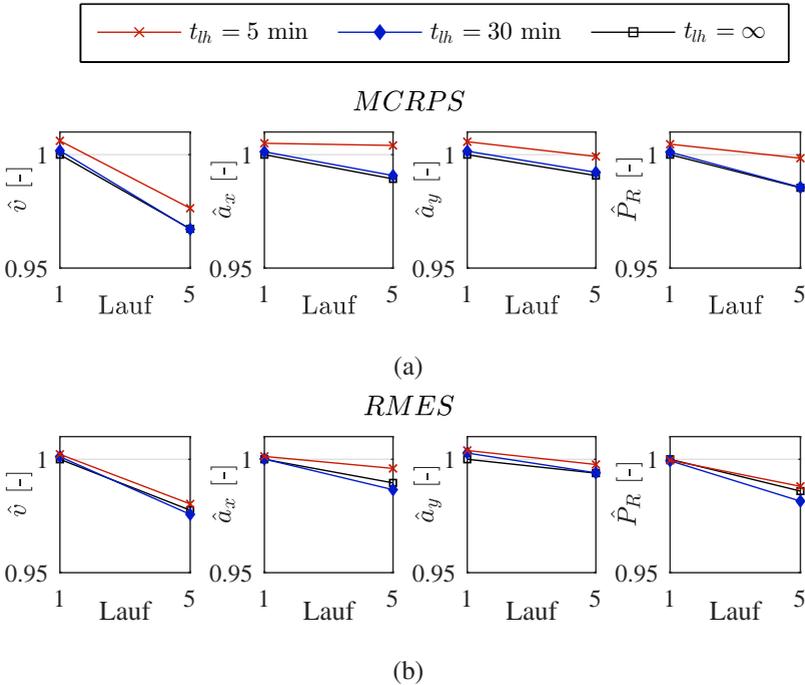


Abb. 3.32: Mittlere Abweichung (*MCRPS*) (a) und mittlere quadratische Abweichung (*RMES*) (b) der Vorhersagen für die Fahrzeugdynamik (v , a_x , a_y , P_R) für die Lernhorizonte t_{lh} . Dargestellt für die Durchläufe 1 und 5 bei $K = 10$ Samples, normiert auf das Resultat ohne Beschränkung des Lernhorizonts im ersten Lauf.

ben im fünften Lauf besser aus. Dabei zeigen sich ähnliche Resultate für den Lernhorizont von 30 Minuten und den unbegrenzten Lernhorizont. Mit 5 Minuten Lernhorizont fallen die Ergebnisse durchgängig am schlechtesten aus. Folglich eignet sich ein zu kurzer Lernhorizont nicht, um die stochastischen Eigenschaften geeignet zu erfassen. Für die nachfolgenden Auswertungen wird der Lernhorizont daher nicht begrenzt.

3.8.3 Referenzmodelle

Die erzielbare Vorhersagegüte ist im Allgemeinen unbekannt und hängt von der Unsicherheit des zugrundeliegenden Prozesses ab. Eine absolute Bewertung einer erzielten Vorhersagegüte ist daher nur eingeschränkt möglich. Um die erzielten Vorhersagegüten in Relation zu setzen, werden daher andere Vorhersagemodelle als Referenz verwendet. Der Vergleich der Vorhersagemodelle kann zur Analyse und Ableitung individueller Stärken und Schwächen der Vorhersagemodelle eingesetzt werden.

Ein in der Literatur häufig verwendetes Modell, das ohne den Einsatz von Streckendaten auskommt, sind Markov-Ketten in der Dimension der Vorhersagegröße (siehe Abschnitt 3.2.2). Da Markov-Ketten üblicherweise ebenfalls zur Erzeugung von Sample-Vorhersagen eingesetzt werden, können diese als stochastisches Referenzmodell für das in dieser Arbeit vorgestellte Verfahren verwendet werden. Um weiterhin den Einfluss der Berücksichtigung der Unsicherheit zu untersuchen, soll als zweite Referenz eine deterministische Punktvorhersage erzeugt werden. Um einen direkten Vergleich der stochastischen Vorhersage und der Punktvorhersage zu ermöglichen, wird die Punktvorhersage ebenfalls mit der selben Transferfunktion erzeugt. Die Erzeugung dieser Referenzvorhersagen wird im Folgenden skizziert.

Markov-Ketten-Vorhersage

Markov-Ketten wurden in der Literatur häufig zur Vorhersage von Fahrzeugdynamikgrößen eingesetzt (siehe z.B. (LPG04, KF09, BRD⁺10, RBD⁺10, MFCS11, DBBK14)). Dabei wird der zulässige Wertebereich der Vorhersagegröße in M Wertebereiche w_i aufgeteilt. Jeder Wertebereich w_i repräsentiert einen Markov-Zustand $S_t = i$. Da die Markov-Kette im Gegensatz zum HMM beobachtbar ist, können die Übergangswahrscheinlichkeiten der Zustände direkt ermittelt werden (vgl. (DBBK14)). Diese Rekursionsgleichung hat für die Übergangswahrscheinlichkeit $p_{ij} = P(S_t = j | S_{t-1} = i)$ nach n -Schritten die Form

$$p_{ij,n} = \frac{\lambda_i - 1}{\lambda_i} p_{ij,n-1} + \frac{1}{\lambda_i} \delta_{ij} \quad (3.92)$$

mit

$$\begin{aligned} \lambda_i &= \min(n_{i,n}, n_{max}), \\ n_{i,n} &= n_{i,n-1} + \sum_j^M \delta_{ij} \\ \delta_{ij} &= \begin{cases} 1 & \text{falls } S_n = j, S_{n-1} = i \\ 0 & \text{sonst} \end{cases} \end{aligned} \quad (3.93)$$

$n_{i,n}$ ist dabei die Anzahl an Transitionen, die den Zustand i verlassen und λ_i der bereits bekannte rekursive Gewichtungparameter. δ_{ij} gibt die aufgetretene Transition an. Die Wahl der Anzahl an Markov-Zuständen wird an (BRD⁺10, RBD⁺10, DBBK14) angelehnt, allerdings werden $M = 17$ statt 16 Zustände verwendet, um eine symmetrische Verteilung um den mittleren Zustand für die Größen Längs- und Querschleunigung zu ermöglichen. Theoretisch könnte ein mehrdimensionale Markov-Kette erzeugt werden, indem die kombinierten Übergänge aller vier Dimensionen der Vorhersagegröße berücksichtigt werden. Da dies jedoch in einer sehr großen Anzahl an Übergangswahrscheinlichkeiten ($17^4 > 8 \cdot 10^4$) resultieren würde und in der referenzierten Literatur ebenfalls nicht erfolgt, wird für jede Vorhersagegröße (v, a_x, a_y, P_R) jeweils eine Markov-Kette trainiert. Ausgehend vom aktuellen Zustand (Wertebereich) der Markov-Kette, kann die Sample-Vorhersage direkt aus den Übergangswahrscheinlichkeiten realisiert werden.

Abb. 3.33 zeigt eine beispielhafte Vorhersage der Geschwindigkeit mit einer Markov-Kette mit 10 Samples. Die Hintergrundfarben markieren dabei die Wertebereiche der einzelnen Markov-Zustände. Den Samples wird jeweils der mittlere Wert des zugehörigen Zustands zugeordnet. Es können daher nicht alle 10 Samples unterschieden werden.

Punktvorhersage

Für die Punktvorhersage des vorgestellten Modells wird eine Vorhersage mit den wahrscheinlichsten Werten der Parameter γ erzeugt. Für den Fahrerwunschdynamik-Zustand bedeutet das in der Regel das Beibehalten des gegenwärtig wahrscheinlichsten Zustands. Da der Erwartungswert des autoregressiven Prozesses null ist, wird dieser bei der Punktvorhersage entsprechend nicht berücksichtigt. Die Zielgeschwindigkeit bleibt somit konstant für das aktuelle Geschwindig-

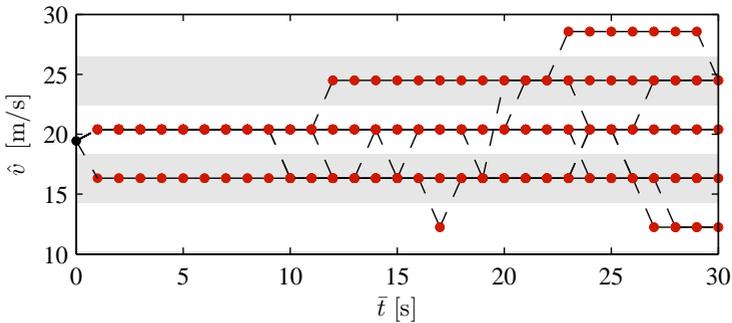


Abb. 3.33: Sample-Vorhersage (10 Samples) der Geschwindigkeit v erzeugt mit einer Markov-Kette. Die Hintergrundfarben markieren die Wertebereiche der einzelnen Markov-Zustände.

keitslimit bzw. beim Mittelwert der Verteilung V_Z . Die Vorhersage entspricht damit einer berechneten Trajektorie der Transferfunktion mit festen Parametern, ähnlich dem Beispiel in Abb. 3.7.

Zur Referenzierung werden die Modelle wie folgt bezeichnet:

SP_{mc} : Monte-Carlo-Vorhersage mit dem vorgestellten stochastischen Prozessmodell Γ und der Transferfunktion f_T .

SP_p : Punktvorhersage mit der Transferfunktion f_T .

MK : Monte-Carlo-Vorhersage mit einer Markov-Kette in der Dimension der Vorhersagegröße.

3.8.4 Ergebnisse mit Realfahrdaten

Zur Validierung und Bewertung der Vorhersagemodelle werden diese mit den durchgeführten Testfahrten evaluiert. Dabei werden die Vorhersagen unter unterschiedlichen Randbedingungen ausgewertet.

Bekannte Strecke

In der ersten Untersuchung wird von einer bekannten Strecke ausgegangen. Um Vergleichbarkeit zu schaffen, werden die Parameter aller Modelle zunächst

mit einem Durchlauf einer Testfahrt initialisiert. In einem zweiten Durchlauf werden bei fortlaufender rekursiver Schätzung der Parameter die Vorhersagen berechnet. Die Strecke wird dabei zunächst als bekannt vorausgesetzt (aktive Zielführung). Der Lernhorizont der rekursiven Schätzverfahren wird nicht begrenzt.

Qualitative Analyse:

Zunächst wird eine qualitative Analyse der Vorhersagen durchgeführt. Abbildung 3.35 zeigt eine Vorhersage für einen Vorausschauhorizont von $T = 30s$ zu einem festen Zeitpunkt $t = 920s$ und den tatsächlichen Verlauf der Fahrzeugdynamik. Die Hintergrundfarbe visualisiert die Abweichung (CRPS) zwischen Vorhersage und tatsächlichem Wert. Der zugehörige Streckenabschnitt besteht aus einer kurvigen Überlandstrecke und ist in Abb. 3.34 abgebildet.

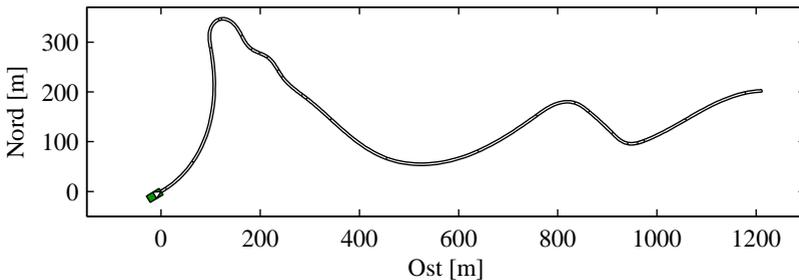


Abb. 3.34: Zugehöriger Streckenabschnitt (kurvige Überlandstrecke) zu den Vorhersagen aus Abb. 3.35.

An diesem Beispiel kann zunächst die Charakteristik der Vorhersagen diskutiert werden. Die Punktvorhersage SP_p (b) bildet den Verlauf der tatsächlichen Trajektorie vor allem bei der Geschwindigkeit relativ gut ab. Im Detail zeigen sich aber Abweichungen z.B. im Geschwindigkeitsniveau bei der Kurvendurchfahrt und dem exakten Beschleunigungsverlauf bzw. dem Zeitpunkt des Rausbeschleunigens aus der Kurve. Die Monte-Carlo-Approximation SP_{mc} (Verteilungsvorhersage) des stochastischen Modells bildet grundsätzlich die gleiche Verlaufscharakteristik ab, variiert in der Vorhersage aber den exakten Verlauf über die einzelnen Samples der Vorhersage. Die Markov-Kette MK kennt keine Streckeninformationen und kann die Kurvendurchfahrt daher nur

ungenügend vorhersagen. Sie liefert hier nur die Information über die grundsätzliche Charakteristik der einzelnen Größen, liefert aber keine spezifische Vorhersage für die Fahrsituation.

Zur genaueren Analyse werden die \bar{t} Sekunden Vorhersagen $\hat{Y}_{\bar{t}}(t - \bar{t})$ eines Modells mit dem tatsächlichen Verlauf der Vorhersagegröße verglichen. $\hat{Y}_{\bar{t}}(t - \bar{t})$ bezeichnet dabei die Vorhersage für \bar{t} Sekunden, berechnet zum Zeitpunkt $t - \bar{t}$ (Vorhersagen mit konstantem Vorhersagezeithorizont \bar{t} , zu unterschiedlichen Zeitpunkten t ermittelt). In Abb. 3.36 sind die Vorhersagen $\hat{Y}_{10}(t - 10)$ und die tatsächlichen Verläufe für den Streckenabschnitt aus Abb. 3.35 dargestellt.

Die Verteilungs- (a) und Punktvorhersage (b) des stochastischen Modells zeigen auch in dieser Analyse zunächst ähnliche Verlaufcharakteristiken. Dabei transportiert die Monte-Carlo-Approximation die Unsicherheit der Größen, während die Punktvorhersage nur den Erwartungswert abbildet. Die Verteilungsvorhersage SP_{mc} weist dabei in Summe etwas geringere Abweichungen auf (CRPS), da sie die Unsicherheit und Streuung berücksichtigt. Beide Vorhersagen geben die Verlaufcharakteristik der Vorhersagegrößen durch die Information der Streckendaten qualitativ gut wieder. Geringfügige Abweichungen, beispielsweise durch ein abweichend erwartetes Geschwindigkeitsniveau ($t \approx 980s$), treten bei beiden Vorhersagen auf. Die Markov-Kette zeigt das schon zuvor beschriebene Verhalten. Für die Geschwindigkeit konzentriert sich die vorhergesagte Verteilung um das aktuelle Geschwindigkeitsniveau, charakteristische Manöver wie Kurven werden aber nicht vorhergesagt. Dementsprechend treten die größten Abweichungen bei den Kurvendurchfahrten auf. Für die übrigen Vorhersagegrößen transportiert die Markov-Kette bei diesem Vorhersagehorizont nur noch unspezifische Informationen. Manövercharakteristiken oder das erwartete Niveau von z.B. der Längsbeschleunigung werden kaum wiedergegeben.

In Anhang A.10 sind die entsprechenden Vorhersagen der Modelle für andere Vorhersagehorizonte ($\bar{t} = 2s$ und $\bar{t} = 20s$) abgebildet. Hier zeigt sich, dass die Markov-Kette schon für einen Vorhersagehorizont von 2s deutlich vom Ist-Verlauf abweicht, während beide Vorhersagen mit dem stochastischen Modell (SP_{mc} und SP_p) hier noch deutlich präziser sind. Bei 20s Vorhersagehorizont sind die Fehler aller Vorhersagemodelle erwartungsgemäß größer, dennoch kann mit den auf Streckendaten basierenden Modellen die Verlaufcharakteristik noch relativ gut vorhergesagt werden.

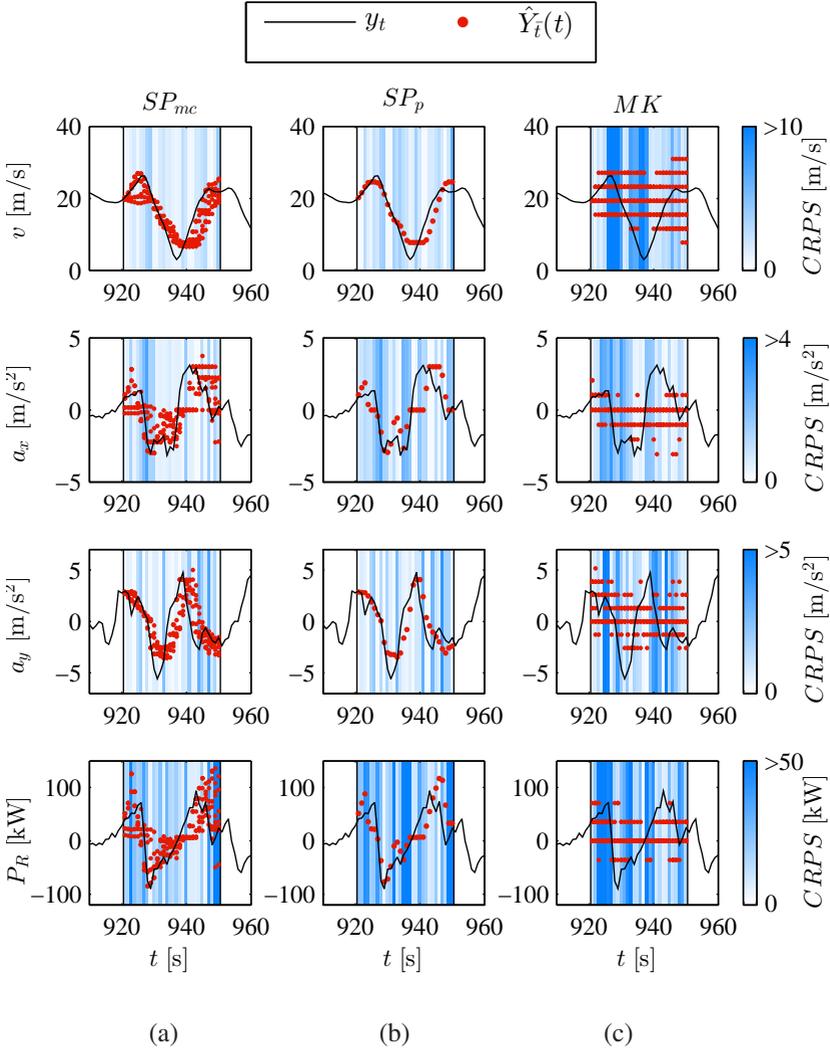


Abb. 3.35: Realer Verlauf (y_t) und die Vorhersage ($\hat{Y}_t(t)$) für $T = 30s$ zum Zeitpunkt $t = 920s$ der Fahrzeugdynamik (v , a_x , a_y und P_R) mit dem stochastischen Modell (a), der Punktvorhersage (b) und der Markov-Kette (c). Die Hintergrundfarbe indiziert die Vorhersagegüte (CRPS) für diesen Zeitpunkt.

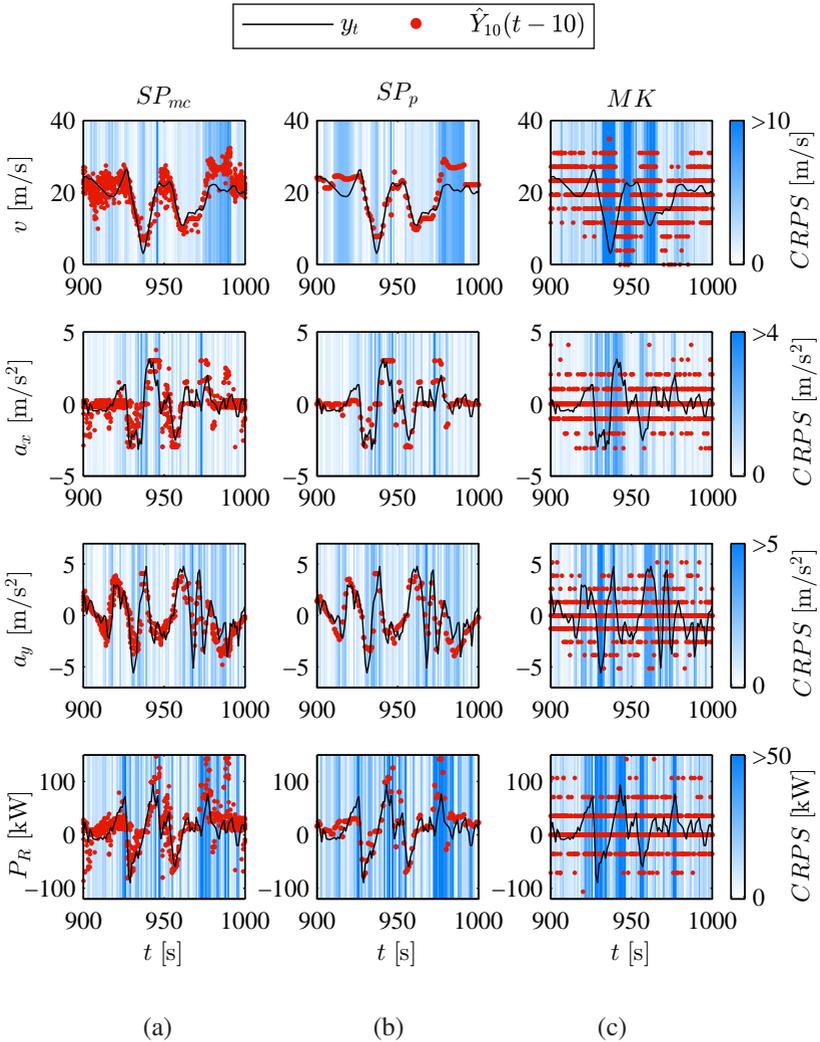


Abb. 3.36: Realer Verlauf (y_t) und die 10 Sekunden Vorhersage ($\hat{Y}_{10}(t-10)$) der Fahrzeugdynamik (v , a_x , a_y und P_R) für den Zeitpunkt t mit der Verteilungsvorhersage des stochastischen Modells SP_{mc} (a), der Punktvorhersage SP_p (b) und der Markov-Kette MK (c). Die Hintergrundfarbe indiziert die Vorhersagegüte (CRPS) für diesen Zeitpunkt.

Abbildung 3.37 zeigt die Geschwindigkeits-Vorhersagen für eine Autobahn-Situation (entsprechend den Streckendaten aus Abb. 3.3). Für Fahrer A (Abb.

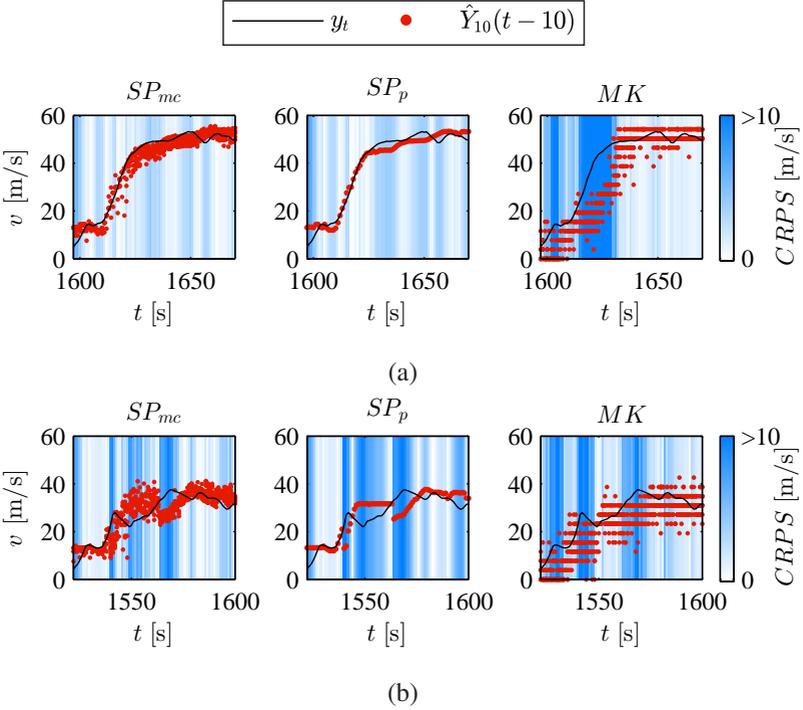


Abb. 3.37: Realer Verlauf (y_t) und die 10 Sekunden Vorhersage ($\hat{Y}_t(t-\bar{t})$) der Fahrzeugdynamik (v , a_x , a_y und P_R) für den Zeitpunkt t mit dem stochastischen Modell (Links), der Punktvorhersage (Mitte) und der Markov-Kette (Rechts) für zwei beispielhafte Fahrer ((a) und (b)). Die Hintergrundfarbe indiziert die Vorhersagegüte (CRPS) für diesen Zeitpunkt.

3.37(a)) liegt eine freie Strecke vor und die Vorhersage mit den Streckendaten liefert deutlich bessere Resultate als die Markov-Kette. Treten Störungen auf, die nicht im erklärenden Modell berücksichtigt werden, wie zum Beispiel bei Fahrer B (Abb. 3.37(b)), zeigen sich auch bei Verwendung der auf Streckendaten basierenden Vorhersagen stellenweise größere Abweichungen. Wobei die Abweichungen mit der Punktvorhersage (SP_p) in dieser Situation erneut größer sind als mit der Monte-Carlo-Vorhersage (SP_{mc}). Die Markov-Kette

(*MK*) erzielt in diesem Beispiel eine vergleichbare Vorhersagegüte wie die auf Streckendaten basierenden Modelle.

Diese beiden Beispielsituationen verdeutlichen die unterschiedlichen Charakteristiken der Vorhersagemodelle. Die Markov-Kette bildet die grundsätzliche Verteilungs- und Übergangscharakteristik der Vorhersagegrößen ab, enthält aber kaum situationsspezifische Informationen. Dementsprechend treten große Abweichungen bei Manövern wie einer Autobahnauffahrt auf. Die auf Streckendaten basierenden Vorhersagen transportieren fundierte manöverspezifische Informationen. Abweichungen treten hier vor allem durch Störeinflüsse auf, die nicht in der Modellformulierung enthalten sind und somit auch nicht berücksichtigt werden können.

Quantitative Analyse:

Für die quantitative Bewertung werden die Vorhersagen mit den zuvor eingeführten Bewertungsgrößen analysiert. Die Ergebnisse werden jeweils über alle Testfahrer gemittelt. Abbildung 3.38(a) zeigt den Vergleich der Bewertungsgrößen über den Vorhersagehorizont \bar{t} für Verteilungsvorhersagen des stochastischen Modells SP_{mc} (blau), der Markov-Kette *MK* (rot) und der Punktvorhersage SP_p (schwarz) bei Sample-Größe $K = 10$.

Die Vorhersagen der Geschwindigkeit erweisen sich für alle Zeithorizonte als am besten mit dem stochastischen Modell basierend auf Streckendaten, wobei die Vorhersagegüte für alle Modelle mit größerem Vorhersagehorizont abnimmt. Die Punktvorhersage ist bezüglich der mittleren absoluten Abweichung (*MCRPS*) vergleichbar mit der Markov-Kette, bei quadratischer Gewichtung des Abstands (*RMES*) schneidet die Markov-Kette schlechter ab. Dies unterstützt die Interpretation aus der qualitativen Analyse, dass die Punktvorhersage mit Streckendaten bessere Vorhersagen hinsichtlich des Verlaufs bzw. Niveaus der Vorhersagegröße macht, durch die Vernachlässigung der Unsicherheit aber schlechter im Bezug auf die Berücksichtigung der Streuung (Kalibrierung) abschneidet. Die Vorhersage der Markov-Kette berücksichtigt die Unsicherheit, schneidet aber durch das Fehlen situationsspezifischer Informationen vor allem im mittleren quadratischen Fehler (*RMES*) schlechter ab als die Vorhersagen mit Streckendaten. Die stochastische Vorhersage mit Streckendaten verknüpft die Vorteile einer Vorhersage mit Trajektorienmodellierung mit der Berücksichtigung der Unsicherheit und hat insgesamt den geringsten Vorhersagefehler.

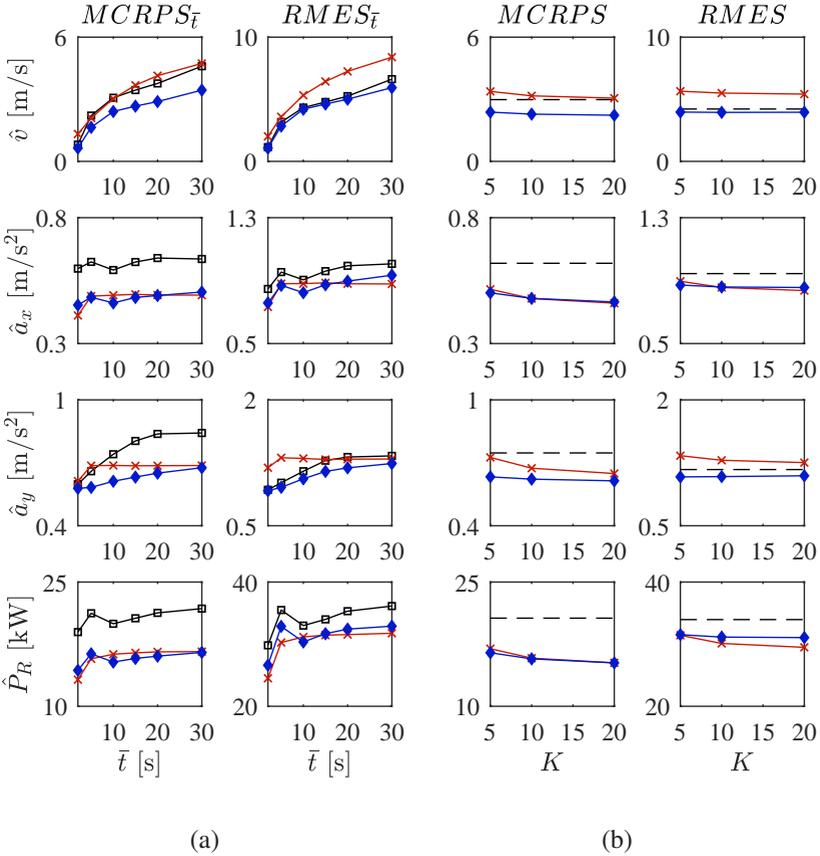


Abb. 3.38: (a) Mittlere Abweichung $MCRPS_{\bar{t}}$ und mittlere quadratische Abweichung $RMES_{\bar{t}}$ über den Vorhersagehorizont \bar{t} bei Sample-Größe $K = 10$. (b) Gemittelte Ergebnisse bei variiert Sample-Größe K . Ergebnisse für: Stochastisches Modell SP_{mc} (blau), Punktvorhersage SP_p (schwarz) und Markov-Kette MK (rot).

Die Vorhersagegüte der Längsbeschleunigung und Radleistung ist vergleichbar für die Markov-Kette und die Verteilungsvorhersage SP_{mc} , die Punktvorhersage SP_p liefert hier die schlechtesten Ergebnisse. Allgemein nimmt die Vorhersagegüte hier mit längerem Zeithorizont nur geringfügig ab. Dies deutet darauf hin, dass durch die Volatilität der Längsbeschleunigung die Vorhersagen bereits bei sehr kurzen Zeithorizonten nur mit einer begrenzten Genauigkeit getroffen werden können. Diese Interpretation wird auch durch das schlechte Abschneiden der Punktvorhersage gestützt, die keine Unsicherheiten in der Vorhersage berücksichtigt. Da die Radleistung vor allem im Verlauf stark von der Längsbeschleunigung geprägt wird, ist hier eine ähnliche Charakteristik der Ergebnisse zu erwarten gewesen.

Bei der Querbeschleunigung sind die Verteilungsvorhersage SP_{mc} und die Markov-Kette in der mittleren Abweichung ($MCRPS$) ebenfalls deutlich besser als die Punktvorhersage SP_p . Die Variante SP_{mc} hat dabei etwas geringere Abweichungen, als die Markov-Kette. Bei quadratischer Gewichtung des Abstands ($RMES$) schneidet die Markov-Kette am schlechtesten ab und die beiden Vorhersagen mit Streckendaten liefern ein vergleichbares Ergebnis.

Zusammenfassend erzielt die Monte-Carlo-Approximation SP_{mc} des stochastischen Modells vor allem für die Geschwindigkeit und Querbeschleunigung die beste Vorhersagegüte. Im $RMES$ ist die Markov-Kette für diese Größen durchgängig am schlechtesten. Hier tritt der Vorteil bei der Verwendung von Streckendaten somit besonders in den Vordergrund. Bei Längsbeschleunigung und Radleistung sind die Vorhersagegüten der beiden Verteilungsvorhersagen (SP_{mc} und MK) vergleichbar, die Punktvorhersage schneidet hier am schlechtesten ab. Die Vernachlässigung der Unsicherheit (Punktvorhersage) erweist sich gerade in der mittleren Abweichung ($MCRPS$) als Nachteil, während bei der mittleren quadratischen Abweichung ($RMES$) in Summe die Vorhersage ohne Streckendaten (Markov-Kette) zurückfällt.

Abbildung 3.38(b) zeigt den Zusammenhang zwischen der totalen gemittelten Vorhersagegüte ($MCRPS$ und $RMES$) über einer variierten Sample-Größe K . Erwartungsgemäß nimmt der Fehler der stochastischen Vorhersagen mit zunehmender Sample-Größe geringfügig ab. Da der Unterschied hier aber nicht signifikant ist, kann der Einfluss des Fehlers durch die Ungenauigkeit einer Monte-Carlo-Approximation der Verteilungen als klein gegenüber dem allgemeinen Vorhersagefehler angenommen werden.

Das ähnliche Abschneiden der stochastischen Vorhersagen SP_{mc} und MK in den Bewertungsgrößen für Längsbeschleunigung und Radleistung überrascht nach der qualitativen Analyse der Beispielsituationen. In einer subjektiven Analyse scheint die auf Streckendaten basierende Vorhersage hier deutlich treffsichere Vorhersagen zu liefern. Da die Bewertungsgrößen $MCRPS$ und $RMES$ eine kombinierte Bewertung von Schärfe und Kalibrierung der Vorhersagen darstellen, wird im Folgenden die Schärfe der Vorhersagen über die Breite der zentralen Vorhersageintervalle untersucht. Abbildung 3.39 zeigt die Entwicklung der Breite des zentralen 75%-Vorhersageintervalls über den Vorhersagehorizont für das stochastische Modell und die Markov-Kette. Es zeigt sich übergreifend über alle Vorhersagegrößen, dass das stochastische Modell deutlich schmalere Vorhersageintervalle liefert als die Markov-Kette. Als Schlussfolgerung lässt sich ableiten, dass SP_{mc} somit zwar schärfere Vorhersagen generiert und das Niveau der Größen besser vorhersagt, aber im statistisch strengen Sinne schlechter kalibriert ist.

Unbekannte Strecke

Da die Markov-Kette im Rahmen dieser Arbeit zwangsläufig mit den Trainingsdaten der befahrenen Teststrecke trainiert wird, ist eine sinnvolle Referenz für eine unbekannte Strecke hier nicht möglich. Daher wird an dieser Stelle nur ein Vergleich der auf Streckendaten basierenden Vorhersagemodelle mit bekannter und unbekannter Routenföhrung durchgeführt. Da Abbiegungen und

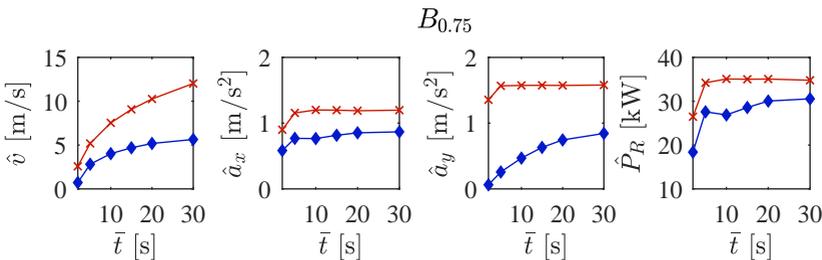


Abb. 3.39: Über alle Fahrten gemittelte Breite des 75%-Vorhersageintervalls der Fahrzeugdynamik (v , a_x , a_y und P_R) für den Vorhersagehorizont \bar{t} bei Sample-Größe $K = 10$ für Vorhersagen des stochastischen Modells SP_{mc} (blau) und der Markov-Kette MK (rot).

Kreuzungssituationen nur einen begrenzten zeitlichen Anteil an einer gesamten Testfahrt haben, sind keine signifikanten Unterschiede in den mittleren Bewertungsgrößen zu erwarten.

In Tabelle 3.5 sind die Bewertungsgrößen für bekannte und unbekannte Strecke in Prozent, normiert auf die Resultate der Verteilungsvorhersage SP_{mc} bei bekannter Strecke, aufgeführt. Die Abweichung der Geschwindigkeitsvorhersage nimmt bei unbekannter Strecke für das stochastische Modell um $CRPS$ 7% ($RMES$ 10%) zu. Die Vorhersage der Querbeschleunigung wird um 4% (8%) schlechter. Für Längsbeschleunigung und Radleistung ist die Zunahme der Abweichungen deutlich geringer.

Bei der Punktvorhersage verschlechtert sich die Geschwindigkeitsvorhersage um 9% (11%). Die Vorhersage der Querbeschleunigung weist um 7% (9%) höhere Abweichungen auf. Für die Punktvorhersage verschlechtert sich auch die Leistungsvorhersage um >4%.

Bei der Punktvorhersage ist die absolute Zunahme der Abweichung durch eine unbekannte Streckenführung etwas größer als für die stochastische Vorhersage. Durch die zwangsläufig unschärfere Information nimmt aber auch die Abweichung der Monte-Carlo-Vorhersage zu. Die vergleichsweise geringe Verschlechterung der Vorhersagen in der Längsbeschleunigung und Radleistung verdeutlicht, dass diese beiden Größen auch schon mit bekannter Routenführung schwerer vorherzusagen sind.

3.8.5 Fazit

Die Analyse zeigt, dass das stochastische Modell basierend auf Streckendaten die grundsätzliche Charakteristiken der Vorhersagegrößen deutlich spezifischer abbildet als die Zeitreihen-Modellierung mit einer Markov-Kette. Die Markov-Kette bildet für die volatileren Zustände (a_x , a_y und P_R) zwar die grundsätzliche Streuung ab, situations- oder manöverspezifische Informationen können hier aber kaum wiedergegeben werden. Die Punktvorhersage schneidet in der quantitativen Bewertung insgesamt am schlechtesten ab, da sie die Unsicherheit der Vorhersagen zwangsläufig nicht berücksichtigen kann.

Dies verdeutlicht die grundsätzlichen Stärken und Schwächen der Vorhersagemodelle: **Erklärende Modelle** (hier die auf Streckendaten basierenden

Tabelle 3.5: Mittlere Abweichung *MCRPS* und mittlere quadratische Abweichung *RMES* für Vorhersagen der Fahrzeugdynamik (v , a_x , a_y und P_R) mit dem stochastischen Modell bei unbekannter Strecke und der Punktvorhersage mit bekannter und unbekannter Strecke. Angaben in Prozent, bezogen auf die Ergebnisse des stochastischen Modells bei bekannter Strecke.

	Stochastisches Modell		Punktvorhersage			
	unbekannte Strecke		bekannte Strecke		unbekannte Strecke	
	<i>MCRPS</i>	<i>RMES</i>	<i>MCRPS</i>	<i>RMES</i>	<i>MCRPS</i>	<i>RMES</i>
v	107.3 %	110.6 %	130.7 %	106.9 %	139.3 %	118.0 %
a_x	100.2 %	101.1 %	129.1 %	109.9 %	130.4 %	111.1 %
a_y	104.1 %	108.0 %	120.1 %	107.8 %	126.9 %	116.2 %
P_R	101.5 %	102.5 %	131.3 %	109.0 %	135.5 %	112.4 %

Modelle) enthalten deutlich präzisere Informationen über die aktuelle Situation. Nicht berücksichtigte Störungen und Einflüsse können aber zu systematischen Abweichungen führen. Durch die Modellierung der Unsicherheit in der Dimension der Steuerparameter des Modells ist die statistische Inferenz und Kalibrierung mit höheren Schwierigkeiten verbunden. Ein **Zeitreihenmodell** (hier die Markov-Kette) arbeitet direkt in der Dimension der Vorhersagegröße. Durch diese direkte Modellierung kann die Streuung unmittelbar ermittelt werden und somit eine bessere Kalibrierung erzielt werden. Die sehr unscharfen Vorhersagen des Modells spiegeln dabei aber nur grundsätzliche Charakteristiken wieder und liefern somit wenig situative Informationen.

Es ist dabei zu beachten, dass bei den quantitativen Bewertungsgrößen (*MCRPS* und *RMES*) ein zeitschrittweiser Vergleich von Vorhersage und Realisierung erfolgt. Zeitkorrelationen und -verläufe werden somit nicht berücksichtigt. Ebenso wird keine Gewichtung der Relevanz von Manövern oder Situationen vorgenommen. Die Bewertungsgrößen geben damit zwar einen Aufschluss über die allgemeine Abweichung und Güte der Vorhersagemodelle, eine systemspezifische Eignung und Qualität der Vorhersagen kann daraus aber nicht direkt abgeleitet werden.

4 Vorausschauende Steuerung von Fahrzeugsystemen

4.1 Stochastisch optimale Regelung

Wie bereits in Abschnitt 2.2 beschrieben, formuliert sich das stochastische Optimalsteuerungsproblem im allgemeinen Fall als

$$V^* = \min_{\underline{u}} \mathbb{E}[V_T] \quad (4.1a)$$

$$\text{u. d. N.: } X_{\bar{t}} = f_s(X_{\bar{t}-1}, u_{\bar{t}-1}, \hat{Y}_{\bar{t}-1}), \quad \forall \bar{t}, \quad (4.1b)$$

$$u \in \mathcal{U}, x \in \mathcal{X} \quad \forall \bar{t}, \quad (4.1c)$$

wobei das zu minimierende Gütemaß über den Erwartungswert der kumulierten Schrittgüten $\mathbb{E}[V_T]$ mit

$$\mathbb{E}[V_T] = \mathbb{E}[J_f(X_T, \hat{Y}_T)] + \sum_{\bar{t}=0}^{T-1} \mathbb{E}[J_s(X_{\bar{t}}, u_{\bar{t}}, \hat{Y}_{\bar{t}})] \quad (4.2)$$

definiert wird. Im Kontext dieser Arbeit wird von einem diskreten und endlichen zulässigen Wertebereich \mathcal{U} der Steuergröße u ausgegangen.

Für die Lösung des Optimalsteuerungsproblems muss dabei nach den Eigenschaften des Systems bzw. der Übertragungsfunktion unterschieden werden. Die zuvor behandelten Vorhersagegrößen y werden aus der Sicht des zu regelnden Systems als Umgebungsgrößen bezeichnet. Dabei wird im Folgenden vorausgesetzt, dass die Verteilungen \hat{Y} der Umgebungsgröße y durch Sample-Vorhersagen \hat{Y}_K gegeben sind.

Ist die optimale Steuertrajektorie \underline{u}^* durch Lösen des Optimalsteuerungsproblems bekannt, wird der erste Wert der optimalen Steuertrajektorie u_0^* auf das System angewendet. Diese Verfahrensweise wird als One-Step-MPC bezeichnet.

net. Das Optimalsteuerungsproblem wird dabei in jedem Rechenzyklus Δt gelöst.

Sei \underline{u} folgend ein realisierter Vektor optimaler Ein-Schritt-Steuergrößen mit

$$\underline{u} = [u_0, u_1, \dots, u_{T-1}] = [u_0^*(t=0), u_0^*(1), \dots, u_0^*(T-1)] , \quad (4.3)$$

wobei $u_0^*(t)$ der erste Wert der optimalen Steuertrajektorie berechnet zum Zeitpunkt t ist sowie \underline{x} die zugehörige resultierende Zustandstrajektorie. Entsprechend der Gütefunktion V_T des Optimalsteuerungsproblems lässt sich eine realisierte Steuer- bzw. Zustandstrajektorie mit der erzielten Regelgüte R mit

$$R = J_f(x_T, y_T) + \sum_{t=0}^{T-1} J_s(x_t, u_t, y_t) \quad (4.4)$$

bewerten. Die bestmögliche erzielbare Regelgüte für eine Fahrt kann durch Lösen des Optimalsteuerungsproblems mit der tatsächlichen Realisierung \underline{y} der Vorhersagegröße (Vektor der Fahrzeugdynamikgrößen entsprechend Gleichung 3.8) ermittelt werden. Diese wird im Folgenden als R_{opt} bezeichnet. Die erzielte Regelgüte R kann somit zur Bewertung der Regelung sowie zum direkten Vergleich der Eignung unterschiedlicher Vorhersagen für ein System herangezogen werden.

4.2 Aktive und Adaptive Aerodynamik

Nachdem in den vorherigen Abschnitten Lösungsmöglichkeiten des Optimalsteuerungsproblems behandelt wurden, soll in den folgenden Abschnitten die Anwendung der Vorhersagen für vorausschauende Regelungen an Beispielsystemen evaluiert und diskutiert werden. Hierfür wird zunächst eine vorausschauende Steuerung einer aktiven Aerodynamik als Systembeispiel mit einem diskreten Zustandsraum betrachtet.

Viele Sportwagen der aktuellen Generation sind mit unterschiedlichen adaptiven bzw. aktiven Aerodynamik-Elementen ausgestattet. Der Porsche 911 Turbo besitzt beispielsweise einen verstellbaren Bugspoiler sowie einen ebenfalls mehrstufig verstellbaren Heckflügel. Die Ausgangsstellung der Verstellelemente ist dabei auf hohe Alltagsstauglichkeit und große Böschungswinkel ausgelegt.

Der Bugspoiler besteht aus einem pneumatisch ausfahrbaren Elastomer. Der Heckflügel wird elektrisch angesteuert und ist in der Ausfahrhöhe und Anstellung variabel. Teilweises Ausfahren der Aerodynamikelemente führt dabei zunächst zu einer Reduktion der Auftriebswerte und damit erhöhter Fahrstabilität. Bei voll ausgefahrenen Aerodynamikelementen wird zusätzlicher Abtrieb an Vorder- und Hinterachse erzeugt um Fahrstabilität und Performance weiter zu erhöhen. Der Luftwiderstand ist dabei erhöht gegenüber der eingefahrenen Stellung und der Zwischenstellung. (vgl. (MWP14, Por))



Abb. 4.1: Ausfahrbarer Heckflügel und verstellbarer Bugspoiler eines Porsche 911 Turbo. ©Dr. Ing. h.c. F. Porsche AG

Ein weiteres Modell mit adaptiven Aerodynamikelementen ist der Porsche 911 Carrera. Der ausfahrbare Heckspoiler des Porsche 911 Carrera dient dazu, den Hinterachs-Auftrieb und den Luftwiderstand bei höheren Geschwindigkeiten zu reduzieren. Die Verstellung erfolgt ebenfalls Geschwindigkeitsabhängig. Durch Ausfahren des Spoilers wird der Luftwiderstandsbeiwert von $c_W = 0.31$ auf $c_W = 0.29$ gesenkt. (Sch13)

Die Verstellung solcher adaptiver Aerodynamik-Elemente erfolgt dabei üblicherweise abhängig von festen Geschwindigkeitsschwellwerten oder durch manuelle Bedienung, beispielsweise über die Wahl eines entsprechenden Fahrprogramms (MWP14, Sch13). Beim Einsatz von geschwindigkeitsabhängigen Verstellungsschwellen sind dabei Stellhysteresen notwendig, um ein häufiges Verstellen der Elemente bei Pendeln um die entsprechende Geschwindigkeitsschwelle zu verhindern. Auf Performanz ausgerichtete Stellungen (erhöhter Abtrieb, erhöhter Luftwiderstand) werden dabei über ein gewähltes Fahrprogramm oder manuelle Einstellung der Position angesteuert, da eine situationsangepasste Wahl der Stellung ohne Informationen über die voraus liegende Strecke nicht möglich ist. Der situationsangepassten Steuerung stehen dabei die Trägheit der Stellglieder und die schlechte Vorhersehbarkeit querdynamischer Anforderungen entgegen. Zwar kann die Verstellzeit bei Einsatz hydraulischer Stellglieder gegenüber elektrischen Stellgliedern reduziert werden, aber es ist dennoch zu beachten, dass Verstellungen der Aerodynamikelemente während transients Übergänge (Einlenken in eine Kurve) vermieden werden sollten, da sich durch die veränderte Auftriebsbalance auch die fahrdynamische Charakteristik des Fahrzeugs ändert. Eine auf Performanz ausgerichtete Stellung sollte daher gewählt werden, bevor fahrdynamische Anforderungen entstehen, um die Fahrstabilität entsprechend zu erhöhen und keine für den Fahrer unvorhersehbaren Lastwechsel zu generieren.

Im Folgenden wird eine vorausschauende und damit situationsgerechte Steuerung von adaptiven Aerodynamik-Elementen vorgestellt und untersucht.

4.2.1 Systemmodell und Lösung des Optimalsteuerungsproblems

Für das Systemmodell bei dieser Anwendung kann ein diskreter Zustand x definiert werden, der die diskreten Positionen der Aerodynamikelemente abbildet. Es wird davon ausgegangen, dass der Systemzustand innerhalb eines Zeitschrittes $\Delta t = 1$ verstellt werden kann. Mit der Sollverstellung u ist die Systemübertragungsfunktion somit durch

$$\begin{aligned} x_{t+1} &= f_s(x_t, u_t, y_t) = x_t + u_t, \\ x &\in [0, 1, \dots], \quad u \in [\dots, -1, 0, 1, \dots] \end{aligned} \quad (4.5)$$

gegeben.

Die Lösung des Optimalsteuerungsproblems für diesen Fall kann im Allgemeinen mittels dynamischer Programmierung gefunden werden. Dynamische Programmierung bezeichnet eine algorithmische Verfahrensweise zur Lösung eines mehrstufigen Entscheidungsproblems und wurde maßgeblich von Richard Bellman auf dem Gebiet der mathematischen Optimierung und Computer Wissenschaften etabliert (siehe z.B. (Bel57, Bel62)). Bellman formulierte dabei das folgende 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“ . (Bel62, S. 15)

Demzufolge kann das Gesamtproblem in einzelne Subprobleme (Zeitschritte) zerlegt werden und die Lösung des Gesamtproblems setzt sich aus den optimalen Lösungen der Teilschritte zusammen. Dies entspricht folgender Umformung des Optimierungsproblems:

$$\begin{aligned} V^* &= \min_{u_{0:T}} \left[\mathbb{E}_{J_f}(x_T, y_T) + \sum_{\bar{t}=0}^{T-1} \mathbb{E}_{J_s}(x_{\bar{t}}, u_{\bar{t}}, y_{\bar{t}}) \right] \\ &= \min_{u_T} \left[\mathbb{E}_{J_f}(x_T, y_T) + \min_{u_{T-1}} \left[\dots + \min_{u_0} \mathbb{E}_{J_s}(x_0, u_0, y_0) \right] \right]. \end{aligned} \quad (4.6)$$

Bei der algorithmischen Umsetzung wird dabei üblicherweise eine Matrix der optimalen Kosten der Teilprobleme für jeden Zustand $x_{\bar{t}}$ sowie eine Matrix der optimalen Aktionen $u_{\bar{t}-1}$, die zu diesen Kosten geführt haben, definiert. Die Matrix der optimalen Kosten sei $V = V(x_{\bar{t}}, \bar{t})_{\|\mathcal{X}_d\| \times T}$, die Matrix der optimalen Aktionen $\Pi = \Pi(x_{\bar{t}}, \bar{t})_{\|\mathcal{X}_d\| \times T}$ und die zugehörigen Vorgängerzustände $X_v = X_v(x_{\bar{t}}, \bar{t})_{\|\mathcal{X}_d\| \times T}$.

Algorithmus 2 beschreibt die Lösung von Gl. (4.6) mittels dynamischer Programmierung in einer vorwärts orientierten Formulierung. Als Resultat wird die optimale Zustandstrajektorie $x_{1:T}^*$ und die zugehörige optimale Strategie

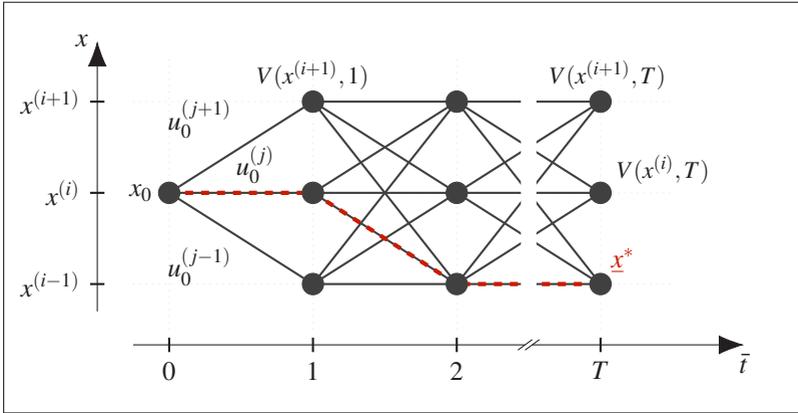


Abb. 4.2: Schematische Darstellung des Suchraums der dynamischen Programmierung für einen Zeithorizont T mit Systemzustand x , Stellgröße u und optimalen Kosten $V(x, t)$ des Zustands x zum Zeitpunkt t sowie einer beispielhaften optimalen Zustandstrajektorie \underline{u}^* .

$\pi^* = u_{0:T-1}^*$ ausgegeben. Der Suchraum der dynamischen Programmierung ist in Abb. 4.2 schematisch dargestellt.

Ist die optimale Steuertrajektorie \underline{u}^* durch Lösen des Optimalsteuerungsproblems bekannt, wird der erste Wert der optimalen Steuertrajektorie u_0^* auf das System angewendet (One-Step-MPC).

4.2.2 Reduktion des Luftwiderstands

Zunächst wird eine beispielhafte Systemkonfiguration mit zwei Zuständen untersucht. Zustand $x = 1$ entspricht dabei einer Design-Position (z.B. eingefahrener Heckspoiler) und ist die Standardposition. Zustand $x = 2$ entspricht einer Position mit reduziertem Luftwiderstand, die entsprechend bei höheren Geschwindigkeiten angefahren werden soll. Die Anzahl der Verstellungen soll dabei möglichst gering sein, um die Bauteilbelastung sowie etwaige Komfortbeeinträchtigung durch Verstellgeräusche gering zu halten.

Algorithmus 2 : Dynamische Programmierung

```

Input : Anfangszustand  $x_0$ 
Output : Optimale Steuer- und Zustandsverläufe  $\underline{u}^*$  und  $\underline{x}^*$ 
begin
   $V(x_{\bar{t}}, \bar{t}) \leftarrow \infty \quad \forall t \in [0, T], \forall x_{\bar{t}} \in \mathcal{X}_d;$ 
   $V(x_0, 0) \leftarrow 0;$ 
  /* Vorwärtsrechnung zur Ermittlung der Matrizen
     der optimalen Kosten und Vorgängerzustände */
  for  $\bar{t} \leftarrow 0, T - 1$  do
    for  $\forall x_{\bar{t}} \in \mathcal{X}_d$  do
      for  $\forall u_{\bar{t}} \in \mathcal{U}_d$  do
         $x_{\bar{t}+1} \leftarrow f_s(x_{\bar{t}}, u_{\bar{t}});$ 
         $V_{x,u} \leftarrow V(x_{\bar{t}}, \bar{t}) + J_s(x_{\bar{t}}, u_{\bar{t}}, y_{\bar{t}});$ 
        if  $V_{x,u} < V(x_{\bar{t}+1}, \bar{t} + 1)$  then
           $V(x_{\bar{t}+1}, \bar{t} + 1) \leftarrow V_{x,u};$ 
           $\Pi(x_{\bar{t}+1}, \bar{t} + 1) \leftarrow u_{\bar{t}};$ 
           $X_v(x_{\bar{t}+1}, \bar{t} + 1) \leftarrow x_{\bar{t}};$ 
      end for
    end for
  /* Ermittlung des optimalen Endzustands */
   $V^* \leftarrow \min_{x_T} V(x_T, T);$ 
   $x_T^* \leftarrow \arg \min_{x_T} [V(x_T, T)];$ 
  /* Rekonstruktion des optimalen Pfads */
  for  $\bar{t} \leftarrow [T, 1]$  do
     $x_{\bar{t}-1}^* \leftarrow X_v(x_{\bar{t}}^*, \bar{t});$ 
     $u_{\bar{t}-1}^* \leftarrow \Pi(x_{\bar{t}}^*, \bar{t});$ 
  end for

```

Das Zielverhalten des Systems wird durch eine generischen Kostenfunktion $J_x(x, y)$ beschrieben. Die relevante Umgebungsgröße ist in diesem Fall die Geschwindigkeit v . Damit gilt:

$$J_x = f(x, v). \quad (4.7)$$

Da der Luftwiderstand quadratisch mit der Geschwindigkeit ansteigt, ist es naheliegend die Kosten $J_x(x = 1, v)$ entsprechend quadratisch mit v zu wählen. Ein Beibehalten der aerodynamischen Position bei geringeren Geschwindigkei-

ten ist unerwünscht. Daher werden für Zustand $x = 2$ entsprechende Kosten für geringere Geschwindigkeiten veranschlagt. Für diese Kosten wird ein quadratischer Anstieg mit sinkender Geschwindigkeit definiert. Abb. 4.3 zeigt die Kostenfunktion J_x abhängig vom Systemzustand x . Die Trade-off-Geschwindigkeit liegt in diesem Fall bei $75 \text{ km/h} \approx 21 \text{ m/s}$. Verstellungen des Systemzustands x werden mit einem konstanten Kostenterm $J_u = J_{u_0}$ für $u \neq 0$ bewertet. Je größer der Wert J_{u_0} gewählt wird, desto geringer ist die angestrebte Anzahl an Verstellungen des Systems. Die Verstellkosten werden im Folgenden mit $J_{u_0} = 5$ gewählt.

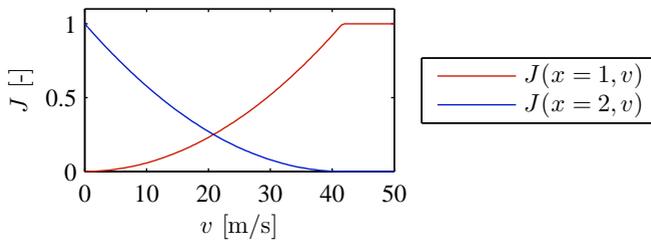


Abb. 4.3: Zustandskosten J_x abhängig vom Systemzustand $x = 1$ (rot) und $x = 2$ (blau) über der Fahrgeschwindigkeit v .

gegeben.

Das Optimalsteuerungsproblem für das dargestellte System kann, wie in Abschnitt 4.2.1 beschrieben, über dynamische Programmierung gelöst werden. Die realisierten Steuer- bzw. Zustandsverläufe \underline{u} und \underline{x} können mit der erzielten Regelgüte R (siehe Gl. (4.4)) bewertet werden.

Für die Vorhersage der Fahrzeuggeschwindigkeit v und in Folge zur Ermittlung der optimalen Strategie werden dabei die bereits zuvor vorgestellten Vorhersagemodelle SP_{mc} , SP_p und MK eingesetzt. Die zugehörigen Zustands- und Steuerverläufe werden mit $\underline{x}_{SP_{mc}}$, \underline{x}_{SP_p} , \underline{x}_{MK} und $\underline{u}_{SP_{mc}}$, \underline{u}_{SP_p} , \underline{u}_{MK} bezeichnet, die Regelgüten entsprechend mit $R_{SP_{mc}}$, R_{SP_p} und R_{MK} . Die Vorhersagen werden wie in Abschnitt 3.8.4 mit einem Initialisierungslauf zur Parameterschätzung berechnet.

Bekannte Strecke: Zunächst werden die Ergebnisse für eine bekannte Routenführung diskutiert.

In Abbildung 4.4 sind die realisierten Zustandsverläufe \underline{x} ((c) und (d)) sowie die optimalen Referenzverläufe \underline{x}_{opt} ((a) und (b)) über der gefahrenen Geschwindigkeit für zwei beispielhafte Ausschnitte zweier Testfahrten dargestellt. In

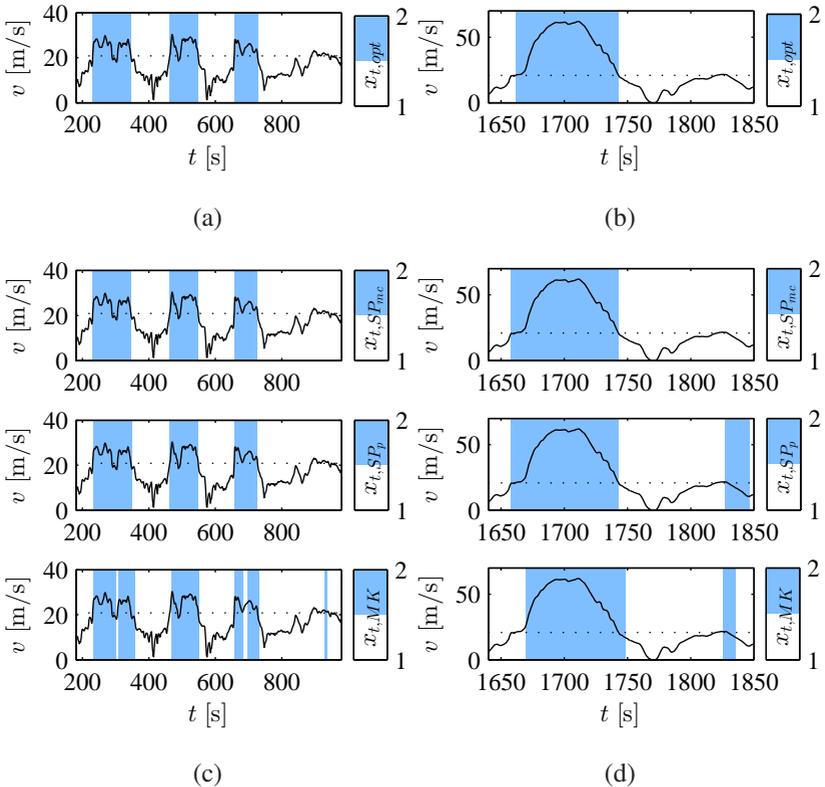


Abb. 4.4: Gefahrene Geschwindigkeit v und optimale Referenzstrategie $x_{t,opt}$ für zwei Beispielfahrten ((a) und (b)) sowie die realisierten Zustandsverläufe ($x_{t,SP_{mc}}$, x_{t,SP_p} und $x_{t,MK}$) mit den unterschiedlichen Vorhersagemodelle (SP_{mc} , SP_p und MK) ((c) und (d)).

der links dargestellten Situation sind die Zustandsverläufe mit den Vorhersagemodellen SP_{mc} und SP_p fast identisch mit der optimalen Referenz. Durch die fehlende Situationsinformation der Markov-Kette (MK) werden unnötige Verstärkungen, beispielsweise bei Kurvendurchfahrt (z.B. $t \approx 300$ s), ausgelöst. In der rechts dargestellten Situation (d) zeigt sich unterschiedliches Verhalten

vor allem bei Auffahren und Verlassen der Autobahn. Während mit den auf Streckendaten basierenden Modellen bereits bei Über- oder Unterschreiten der Trade-off-Geschwindigkeit in die entsprechende Position gewechselt wird, reagiert die Regelung bei Verwendung der Markov-Kette hier verzögert, da das konkrete Wissen über die Situation fehlt. Weiterhin wird mit der Punktvorhersage (SP_p) und der Markov-Kette eine unnötige Verstellung bei $t \approx 1830$ s ausgelöst, die mit dem stochastischen Modell vermieden werden kann.

Abb. 4.5 zeigt die mittlere Regelgüte \bar{R} (normiert auf die mittlere Regelgüte \bar{R}_{opt}) bzw. die Verteilung der Regelgüte R über alle Testfahrer. Die modellbasier-

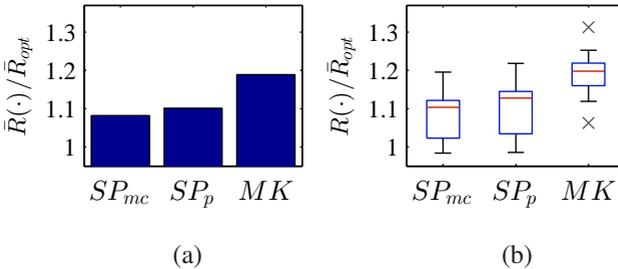


Abb. 4.5: Erzielte Regelgüte normiert auf die mittlere optimale Regelgüte \bar{R}_{opt} für die unterschiedlichen Vorhersagemodelle (SP_{mc} , SP_p und MK), gemittelt über alle Testfahrten. (a) Mittlere Regelgüte \bar{R} , (b) Box-Whisker-Plot von R mit Median, Interquartilbox und Maximal- bzw. Minimalwerten.

ten Vorhersagen (SP_{mc} und SP_p) erzielen jeweils deutlich bessere Regelgüten als die Markov-Kette (MK). Dabei sind die Resultate mit der stochastischen Vorhersage (SP_{mc}) im Mittel etwas besser als mit der Punktvorhersage (SP_p). Das deutlich schlechtere Abschneiden der Markov-Kette in der mittleren Regelgüte über alle Fahrten zeigt ein übereinstimmendes Bild mit den beispielhaften Zustandsverläufen aus Abb. 4.4. Die Markov-Kette ist für dieses Systembeispiel somit deutlich schlechter geeignet und lässt die notwendige Informationsschärfe vermissen.

Diese Beispielsituationen verdeutlichen die Auswirkungen der unterschiedlichen Vorhersagemodelle, die auch in der quantitativen Zielerreichung (Regelgüte R) widerspiegelt werden. Die auf Streckendaten basierenden Vorhersagen schneiden hier deutlich besser ab als die Markov-Kette. Die Verhältnisse der

erzielten Regelgüten spiegeln dabei in etwa die Verhältnisse des *RMES* der Geschwindigkeit wieder, was angesichts der quadratischen Zielfunktion in der Geschwindigkeit mit den Erwartungen übereinstimmt. Die Markov-Kette kann die fehlenden situationspezifischen Informationen folglich nicht durch eine bessere statistische Kalibrierung ausgleichen und führt zu einem unzureichenden Systemverhalten. Die Monte-Carlo-Approximation resultiert in geringfügig besserem Systemverhalten als die Punktvorhersage.

Unbekannte Strecke: In Abb. 4.6 sind die Ergebnisse der auf Streckendaten basierenden Modelle für unbekannte Routenführung dargestellt. Die erzielten

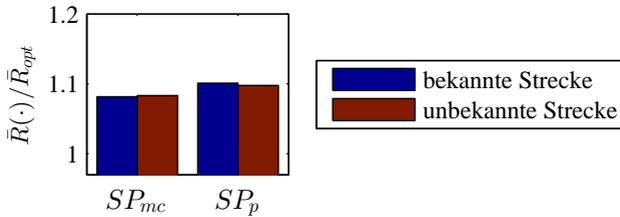


Abb. 4.6: Erzielte mittlere Regelgüte \bar{R} normiert auf die mittlere optimale Regelgüte \bar{R}_{opt} für die auf Streckendaten basierenden Vorhersagemodelle bei bekannter und unbekannter Route.

Regelgüten zwischen bekannter und unbekannter Routenführung unterscheiden sich hier nicht signifikant. Dies ist darauf zurückzuführen, dass die von der Unsicherheit beeinflussten Fahrsituationen nicht die relevanten Entscheidungssituationen für das System sind und somit nur geringfügigen Einfluss auf die Zustandsverläufe haben. Auf eine ausführliche Darstellung der Zustandsverläufe wird daher verzichtet.

4.2.3 Performanzorientierte Aerodynamik

In einem zweiten Beispiel wird das System um eine auf Performanz ausgerichtete Stellung erweitert. Diese dritte Position der Aerodynamikelemente (Systemzustand $x = 3$) entspricht einer Stellung mit erhöhtem Abtrieb, um eine höhere Fahrstabilität und Grenzdynamik zu ermöglichen. Hierfür wird die Kostenfunktion J_x um einen querdynamischen Anteil erweitert. Da die Aerodynamik nicht in Übergangphasen (z.B. Einlenken in eine Kurve) verstellt

werden soll, wird nicht direkt die Querbeschleunigung zum Zeitpunkt t ($a_{y,t}$) in der Zielfunktion berücksichtigt. Stattdessen wird eine virtuelle Querdynamikgröße \tilde{a}_y verwendet. \tilde{a}_y ist der Maximalwert der absoluten Querbeschleunigung über ein gleitendes Zeitfenster mit

$$\tilde{a}_{y,t} = \max_{\tilde{t} \in [t-2, t+3]} |a_{y,\tilde{t}}|. \quad (4.8)$$

Abbildung 4.7 zeigt einen beispielhaften Verlauf der Querbeschleunigung sowie der virtuellen Querdynamikgröße \tilde{a}_y .

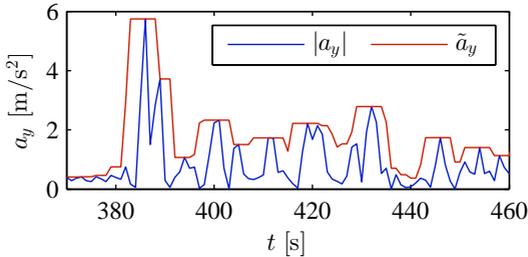


Abb. 4.7: Betragmäßiger Verlauf der Querbeschleunigung a_y sowie entsprechender Verlauf der virtuellen Querdynamikgröße \tilde{a}_y .

Die Zustands-abhängige Zielfunktion J_x wird um diese Querdynamikgröße \tilde{a}_y erweitert:

$$J_x = f(x, v, \tilde{a}_y). \quad (4.9)$$

Dabei werden zur Kostenfunktion aus Abschnitt 4.2.2 für die Zustände $x = 1$ und $x = 2$ zusätzliche Kostenterme für auftretende Querdynamik \tilde{a}_y ergänzt. Für den Zustand $x = 3$ werden entsprechende Kosten für die Abwesenheit von Querdynamik \tilde{a}_y berücksichtigt. Abbildung 4.8 zeigt die Differenz der Zustandskosten für die 3 möglichen Systemzustände über Kombinationen von Geschwindigkeit und Querdynamik. Die Zielfunktion ist dabei so definiert, dass die Querdynamikschwelle, ab der die Performanz-Stellung bevorzugt wird, mit zunehmender Geschwindigkeit abnimmt. Dadurch wird die zunehmende Relevanz der Fahrstabilität bei höheren Geschwindigkeiten berücksichtigt.

Bekannte Strecke: Die erzielten Regelgüten bei bekannter Routenführung für dieses System sind in Abbildung 4.9 dargestellt. Es zeigen sich ähnliche

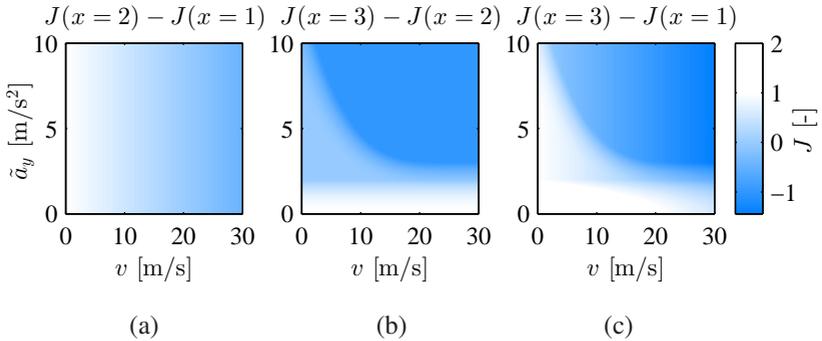


Abb. 4.8: Kostendifferenz $J_x(i, v, \tilde{a}_y) - J_x(j, v, \tilde{a}_y)$ über Fahrgeschwindigkeit v und Querdynamikgröße \tilde{a}_y zwischen den Zuständen 2 und 1 (a), 3 und 2 (b) sowie 3 und 1 (c). In den blauen Bereichen wird der erstgenannte Zustand angestrebt.

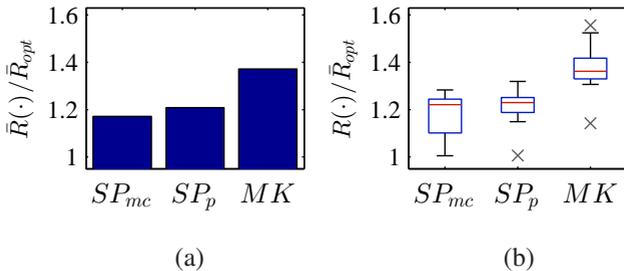


Abb. 4.9: Erzielte Regelgüte normiert auf die mittlere optimale Regelgüte \bar{R}_{opt} für die unterschiedlichen Vorhersagemodelle, gemittelt über alle Testfahrten. (a) Mittlere Regelgüte \bar{R} , (b) Box-Whisker-Plot von R mit Median, Interquartilbox und Maximal- bzw. Minimalwerten.

Verhältnisse wie bei dem Systembeispiel mit zwei Zuständen. Die Ergebnisse mit der Markov-Kette sind deutlich schlechter als die der auf Streckendaten basierenden Vorhersage. Bei den auf Streckendaten basierenden Vorhersagen werden etwas bessere Ergebnisse mit der stochastischen Vorhersage (SP_{mc}) erzielt.

Abbildung 4.10 zeigt einen beispielhaften Ausschnitt der Testfahrten mit den resultierenden Zustandsverläufen \underline{x} bei Verwendung der unterschiedlichen Vorhersagen sowie der optimalen Referenzstrategie. Auffällig ist, dass mit der

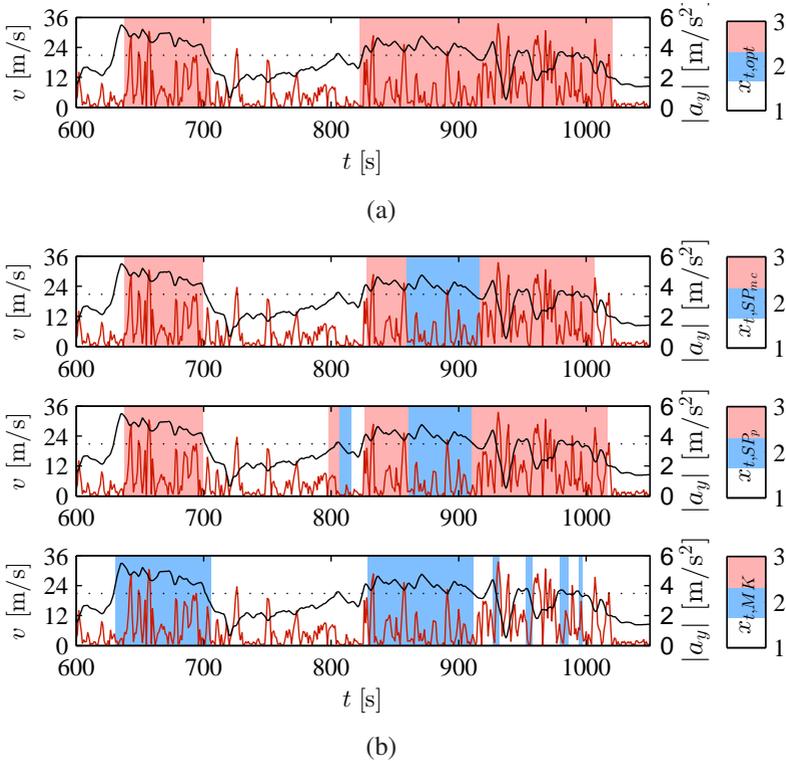


Abb. 4.10: Gefahrene Geschwindigkeit v , Querbeschleunigung a_y und optimale Referenzstrategie $x_{t,opt}$ (a) sowie die realisierten Zustandsverläufe $x_{t,SPmc}$, $x_{t,SPp}$, $x_{t,MK}$ für die unterschiedlichen Vorhersagemodelle (b).

Markov-Ketten-Vorhersage der Performance-orientierte Zustand in diesem Abschnitt nie angesteuert wird. Dies verdeutlicht die mangelnde Schärfe dieser Art von Vorhersage für die dynamischeren Vorhersagegrößen (a_x , a_y), die bereits in den Analysen in Abschnitt 3.8.4 festgestellt wurde. Die Markov-Kette bildet zwar die Unsicherheit und die charakteristische Verteilung der Querdynamik ab, die Information ist dabei aber zu unspezifisch um als Entscheidungsgrundlage für das System dienen zu können. Die Vorhersage ist somit nicht scharf genug und resultiert in einer entsprechend großen Zielabweichung von der Referenzstrategie. Die beiden auf Streckendaten basierenden Vorhersagen re-

sultieren in einem sehr ähnlichen Zustandsverlauf des Systems, wobei mit der Punktvorhersage bei $t \approx 800$ einige unnötige Verststellungen ausgelöst werden.

Um das Auftreten der Systemzustände abhängig von der Fahrgeschwindigkeit und Querbesehleunigung zu untersuchen, sind in Abb. 4.11 die Kombinationen aus Systemzustand x und den Fahrzeugdynamikgrößen für eine beispielhafte Fahrt und die unterschiedlichen Vorhersagemodelle dargestellt. Zur Visualisierung des Zielverhaltens sind die Differenzkosten entsprechend Abb. 4.8 im Hintergrund dargestellt. Diese qualitative Darstellung zeigt, dass die über die Zielfunktion angestrebten Systemzustände mit den auf Streckendaten basierenden Vorhersagen sehr gut umgesetzt werden konnten. Für fast alle Phasen mit hoher Querdynamik wurde der Performance-orientierte Systemzustand ($x = 3$) eingestellt. Mit der Markov-Kette wird dieser Performance-orientierte Zustand über die ganze Fahrt nicht eingesetzt. Die Aussage über fehlende Schärfe der Querdynamikvorhersagen der Markov-Kette lässt sich somit auf die gesamte Strecke übertragen.

Unbekannte Strecke: Bei unbekannter Routenführung ergeben sich auch in diesem Beispiel nur geringfügig abweichende Ergebnisse. Die erzielte Regelgüte verschlechtert sich für beide auf Streckendaten basierenden Modelle, wobei die Verschlechterung für die stochastische Vorhersage etwas größer ausfällt und sich für die stochastische Vorhersage kein signifikanter Vorteil mehr ergibt (siehe Abb. 4.12).

4.2.4 Fazit

Die Beispiele für die Steuerung von aktiven Aerodynamikelementen zeigen, dass auf Streckendaten basierende Vorhersagen eine deutlich bessere Performance ermöglichen als eine reine Zeitreihenmodellierung über eine Markov-Kette. Die Ergebnisse zeigen damit auch, dass die statistische Kalibrierung einer Vorhersage alleine nicht ausreichend für die vorausschauende Steuerung eines Systems ist. Vielmehr ist eine gewisse Schärfe der Vorhersagen erforderlich, um Entscheidungen für eine vorausschauende Steuerung zu ermöglichen. Beim Vergleich der auf Streckendaten basierenden Vorhersagen erweist sich der Einsatz von Verteilungsvorhersagen jedoch als vorteilhaft, da dadurch eine robustere Regelstrategie erzielt werden kann, als mit einer reinen Punktvorhersage.

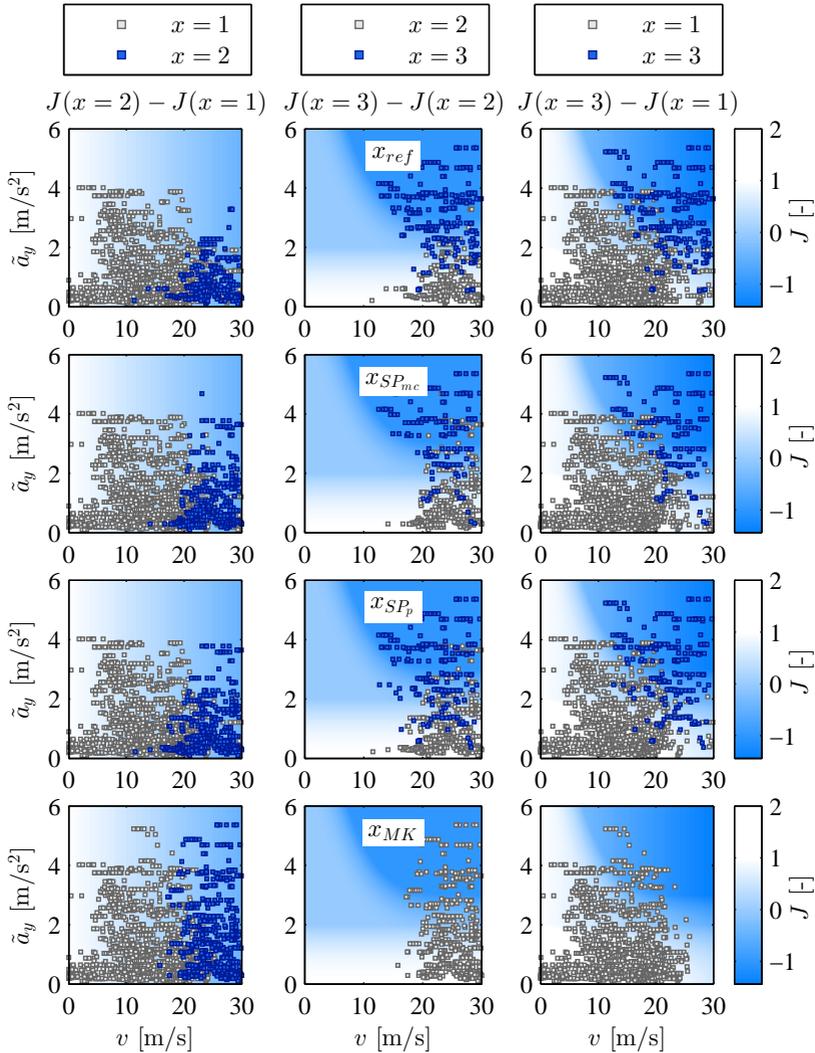


Abb. 4.11: Resultierende Kombinationen aus Systemzustand x (links $x \in \{1, 2\}$, Mitte: $x \in \{2, 3\}$, Rechts: $x \in \{1, 3\}$) und Fahrzeugdynamik (v und \tilde{a}_y) für eine beispielhafte Testfahrt. Ideale Vorhersage (1. Reihe), SP_{mc} (2. Reihe), SP_p (3. Reihe) und MK (4. Reihe). Hintergrundfarbe: Differenz der Kostenfunktion J_x für die Zustände entspr. Abb. 4.8.

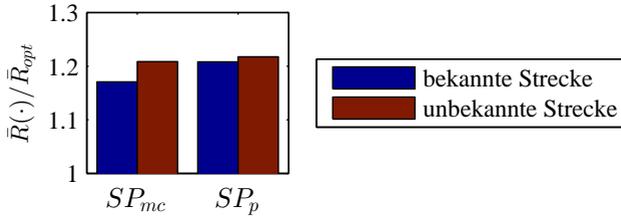


Abb. 4.12: Erzielte mittlere Regelgüte \bar{R} normiert auf die optimale Regelgüte \bar{R}_{opt} für die auf Streckendaten basierenden Vorhersagemodelle bei bekannter und unbekannter Route.

4.3 Vorausschauendes Thermomanagement einer elektrischen Maschine

Für ein zweites Anwendungsbeispiel soll ein System gewählt werden, das die Betrachtung eines kontinuierlichen Zustandsraums \mathcal{X} erfordert. Hierfür kommt ein vorausschauendes Thermomanagement des Fahrzeugs in Betracht.

Vorausschauendes Thermomanagement wurde bereits vielfach für konventionelle Fahrzeuge behandelt (siehe z.B. (Goß09, BLEK10, GS12)). Bei Fahrzeugen mit Verbrennungsmotor ist dabei vor allem die Abhängigkeit der Motorverlustleistung von den mittleren Bauteiltemperaturen von Interesse, da ein Anheben der mittleren Bauteiltemperaturen zu Verbrauchsvorteilen führt. Durch die zunehmende Bedeutung von Elektrofahrzeugen ist auch das intelligente Thermomanagement für elektrische Antriebe zunehmend im Fokus der Forschung. In (Aue15) und (AWWK15) werden zum Beispiel die Potentiale zur Verbrauchsenkung eines Elektrofahrzeugs durch vorausschauendes Thermomanagement betrachtet. Dabei werden die Energiebedarfe für das Thermomanagement der Batterie und der elektrischen Maschine berücksichtigt. Für die gewählte Fahrzeugkonfiguration und den untersuchten Zyklus wird eine mögliche Reduktion des Gesamtenergiebedarfs um bis zu 3.5% ermittelt. Im Rahmen der Untersuchung wird dabei von einem vollständig bekannten Lastprofil ausgegangen. Das Thermomanagement einer elektrischen Maschine soll im Folgenden als weiteres Systembeispiel betrachtet werden, wobei der Fokus auf der Wechselwirkung mit der tatsächlichen Vorhersagbarkeit des Lastprofils liegt.

Generell können elektrische Maschinen in einem weiten Temperaturbereich betrieben werden. Bei der Regelung des Kühlsystems einer elektrischen Maschine sind dennoch unterschiedliche Aspekte zu berücksichtigen. Die zulässige Betriebstemperatur hängt von der Temperaturklasse des verwendeten Isolierungsmaterials der Leiterwicklungen ab (IEC07). Dabei ist zu beachten, dass bereits unterhalb der kritischen Temperatur (Verlust der Isolationsfähigkeit) Alterungseffekte der Isolierung auftreten, sodass die erwartete Betriebsfestigkeit der Maschine durch hohe Temperaturen reduziert wird (RH11). Bei permanent erregten Synchronmaschinen (PSM) ist außerdem die temperaturabhängige Entmagnetisierung des verwendeten Magnetmaterials zu berücksichtigen. Neben reversibler Entmagnetisierung, kann es bei thermischer Überlastung auch zu irreversibler Entmagnetisierung und damit dem Ausfall der Maschine kommen (vgl. (Spe14, WLL08, RKIA10)).

Neben den thermischen Grenzbedingungen sind dabei auch die Temperaturabhängigkeiten der mechanischen und elektrischen Verluste relevant. Die Verluste einer elektrischen Maschine lassen sich vor allem in Kupferverluste (elektrischer Widerstand der Leiter), Eisenverluste (Verluste durch Ummagnetisierung der Stator- und Rotorbleche sowie Wirbelströme in den Blechpaketen) und mechanische Verluste (Reibung an Lager und Dichtungen) aufteilen. Dabei ergeben sich folgende grundlegende Abhängigkeiten bei steigender Temperatur: Die Kupferverluste steigen, die Eisenverluste und die mechanischen Verluste sinken (SH13).

Bei geringen Drehzahlen und hohen Drehmomenten überwiegen im Allgemeinen die Kupferverluste, wodurch sich eine eher geringe Betriebstemperatur empfiehlt. Mit steigender Drehzahl dominieren die Eisenverluste und die optimale Betriebstemperatur steigt entsprechend an. Da bei Synchronmaschinen die Eisenverluste einen großen Anteil der Gesamtverluste stellen, ist dieser Effekt vor allem bei diesem Maschinentyp zu beachten. Generell ergibt sich durch die unterschiedlichen Verlusteffekte eine vom Betriebspunkt abhängige optimale Motortemperatur. (SH13)

Bei Asynchronmaschinen (ASM) haben die Kupferverluste einen größeren Anteil an den Gesamtverlusten, wodurch sich bei kleinen Maschinen eine generell niedrige Betriebstemperatur empfiehlt (SH13). Mit zunehmender Leistung geht der Einfluss der Kupferverluste aber zurück, wodurch bei Maschinen in der Leistungsklasse für Fahrzeugantriebe sich ein anderer Zusammenhang erwarten lässt (SH13). Bei der in (Aue15) untersuchten Konfiguration mit einer ASM

wurde für die meisten Fahrzyklen - übereinstimmend mit diesen Erwartungen - ein höherer Wirkungsgrad bei hoher mittlerer Betriebstemperatur ermittelt. Für die Fahrzyklen, bei denen eine niedrige mittlere Motortemperatur zu einem besseren mittleren Wirkungsgrad führt, überwiegt der Kühlleistungsbedarf die geringeren Motorverluste, sodass auch hier eine höhere Temperatur zu geringerem Verbrauch führt (Aue15).

Für Fahrzeugantriebe lässt sich daraus schließen, dass hohe mittlere Betriebstemperaturen der elektrischen Maschine zu geringeren Verlusten und damit zu einer höheren Reichweite des Fahrzeugs führen. Dieser angestrebten hohen Motortemperatur stehen die Alterungseffekte des Leiterisolationsmaterials und die Entmagnetisierung der Permanentmagnete entgegen. Ziel einer vorausschauenden Regelung eines Kühlsystems einer elektrischen Maschine ist somit der Betrieb der Maschine in einem energieeffizienten Temperaturbereich, ohne kritische Temperaturschwellen zu überschreiten. Die optimale Betriebstemperatur ist hierbei vom Betriebspunkt und dem Maschinentyp abhängig.

4.3.1 Vereinfachtes Systemmodell

Im Folgenden wird der Kühlkreislauf einer elektrischen Maschine bestehend aus einem Wärmetauscher mit elektrisch betriebenem Lüfter und einer elektrischen Kühlmittelpumpe als beispielhafte Systemkonfiguration betrachtet (siehe Abb. 4.13).

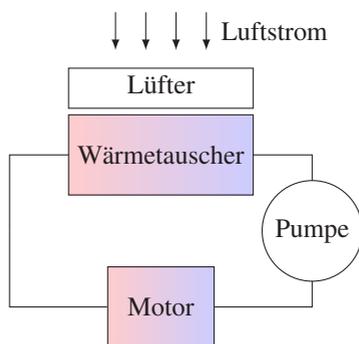


Abb. 4.13: Prinzipdarstellung des betrachteten Kühlsystems.

Zur Abbildung des Temperaturverhaltens wird das Kühlsystem vereinfacht als thermisches Zwei-Massen-System modelliert, bestehend aus der thermischen Masse des Motors und des Kühlmittels. Die (kinetische) Massenträgheit des Kühlsystems sowie Totzeiten durch Fließzeiten des Kühlmittels werden dabei vernachlässigt. Für die Temperaturänderung einer thermischen Masse gilt

$$\dot{\vartheta} = \frac{\dot{Q}}{C}, \quad (4.10)$$

wobei ϑ die Temperatur des Körpers, C die Wärmekapazität des Körpers und \dot{Q} die Summe aller Wärmeströme ist. Wärmeströme in Folge von Wärmestrahlung oder freier Konvektion an die Umgebung werden im Folgenden vernachlässigt.

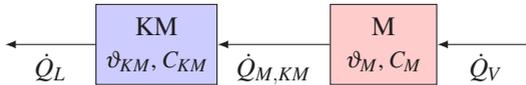


Abb. 4.14: Zwei-Massen-Modell des Kühlsystems mit den thermischen Massen (Temperatur ϑ , Wärmekapazität C) von Motor (M) und Kühlmittel (KM) sowie den zugehörigen Wärmeströmen \dot{Q} .

Für den Motor gilt dabei

$$\dot{\vartheta}_M = \frac{1}{C_M} (\dot{Q}_V - \dot{Q}_{M,KM}) \quad (4.11)$$

mit dem Wärmeeintrag durch die Motorverlustleistung \dot{Q}_V , der Wärmekapazität des Motors C_M und dem Wärmestrom $\dot{Q}_{M,KM}$, der vom Motor an das Kühlmittel übertragen wird. Die Motorverlustwärme berechnet sich dabei aus dem Motorwirkungsgrad η und der geforderten Motorleistung P_M mit

$$\dot{Q}_V = P_V = \frac{1 - \eta}{\eta} \cdot P_M. \quad (4.12)$$

Die geforderte Motorleistung P_M wird wiederum aus der Radleistung P_R und dem mittleren Antriebstrangwirkungsgrad η_A ermittelt:

$$P_M = \begin{cases} \frac{1}{\eta_A} \cdot P_R & \text{falls } P_R > 0, \\ \eta_A \cdot P_R & \text{sonst.} \end{cases} \quad (4.13)$$

Der Motor gibt seine Wärme an das umströmende Kühlmittel ab. Der durch das fließende Kühlmittel abgeführte Wärmestrom $\dot{Q}_{M,KM}$ ergibt sich als

$$\dot{Q}_{M,KM} = \dot{m}_{KM} \cdot c_{p,KM} (\vartheta_{KM,A} - \vartheta_{KM,E}) \quad (4.14)$$

mit dem Kühlmittelmassestrom \dot{m}_{KM} , der spezifischen Wärmekapazität des Kühlmittels $c_{p,KM}$ und der Temperatur des ein- und austretenden Kühlmittels am Motor ($\vartheta_{KM,E}$ bzw. $\vartheta_{KM,A}$). Unter Annahme konstanter Wandtemperatur des Stators (große thermische Masse des Motors gegenüber der des umgebenden Kühlmittels), berechnet sich die Temperaturdifferenz zwischen Ein- und Austritt zu

$$\Delta\vartheta_{KM} = \vartheta_{KM,A} - \vartheta_{KM,E} = \Delta\vartheta_{M,KM} \left(1 - e^{-\frac{\alpha \cdot A}{\dot{m}_{KM} \cdot c_{p,KM}}} \right), \quad (4.15)$$

mit der Temperaturdifferenz $\Delta\vartheta_{M,KM} = \vartheta_M - \vartheta_{KM}$ zwischen Motor und Kühlmittel, dem Wärmeübergangskoeffizienten α sowie der Fläche A zwischen Stator und umgebendem Kühlmedium (BS16). Die Kühlfläche der Außenmantelkühlung berechnet sich mit dem Statoraußendurchmesser D_{Stator} und der Statorlänge l_{Stator} zu

$$A = \pi \cdot D_{Stator} \cdot l_{Stator} . \quad (4.16)$$

Für die Temperatur des Kühlmittels gilt

$$\vartheta_{KM} = \frac{1}{C_{KM}} (\dot{Q}_{M,KM} - \dot{Q}_L) \quad (4.17)$$

mit der Wärmekapazität des Kühlmittels C_{KM} und dem über den Wärmetauscher an die Umgebung abgegebenen Wärmestrom \dot{Q}_L . Der an die Umgebung abgegebene Wärmestrom berechnet sich mit der Temperaturdifferenz zwischen Kühlmittel und Umgebungsluft und der spezifischen Wärmeleistung des Kühlers \dot{q}_L zu

$$\dot{Q}_L = \dot{q}_L (\vartheta_{KM} - \vartheta_L) . \quad (4.18)$$

Die Umgebungstemperatur wird im Folgenden mit $\vartheta_L = 20^\circ\text{C}$ angenommen. Die spezifische Wärmeleistung ist dabei vom Kühlmittelmassestrom \dot{m}_{KM} und

¹⁵ Zur Vereinfachung wird angenommen, dass die Antriebstrangverluste proportional zur Radleistung sind und somit bei $P_R > 0$ auch $P_M > 0$ gilt.

dem Luftmassenstrom \dot{m}_L durch den Kühler abhängig und wird üblicherweise über Kennfelder oder empirische Gleichungen abgebildet (Sch13). Abbildung 4.15 zeigt ein typisches Kühlerkennfeld eines Fahrzeugkühlers mit spezifischer Kühlleistung über Volumenstrom des Kühlmittels und dem Massenstrom der Kühlluft (angelehnt an (Sch13) S. 496).

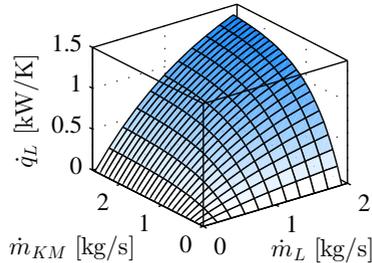


Abb. 4.15: Typisches Kennfeld der spezifischen Wärmeleistung \dot{q}_L für Massenströme von Kühlmittel \dot{m}_{KM} und Kühlluft \dot{m}_L eines Fahrzeugwärmetauschers.

Die Daten der elektrischen Maschine werden entsprechend der Auslegung für ein sportliches E-Fahrzeug in (Gru14) gewählt (PSM). Die Maximalleistung der Maschine ist mit 153 kW angegeben. Dabei ist zu beachten, dass die Maximalleistung vor allem durch die thermische Belastung und den zulässigen Strom der Leistungselektronik begrenzt ist (Füß17). Das Model S der Firma Tesla Motors erreicht die angegebenen Fahrleistungswerte z.B. durch das kurzzeitige Zulassen deutlicher Überbelastungen der Maschine und Leistungselektronik (Lie16). Es wird daher im Folgenden davon ausgegangen, dass die Leistungselektronik höhere Ströme zulässt und durch kurzzeitige Überlastung der Maschine höhere Leistungen bis zu den in den Beispielfahrten geforderten Motorleistungen bereitstellen kann. Die thermische Masse der Maschine wird mit 90% der thermischen Masse eines Eisenkörpers mit den Außenabmessungen der Maschinen geschätzt. Für PSM werden in der Literatur maximale Wirkungsgrade von ca. 95% angegeben. Vereinfachend wird im Folgenden über alle Betriebspunkte mit einem mittleren Wirkungsgrad von $\eta = 92\%$ gerechnet. Der Wirkungsgrad von Getriebeeinheit und Differential (η_A) wird mit 90% angenommen (angelehnt an (KLLS14)). Als Kühlmittel werden 10 Liter Wasser-Glykol-Gemisch angenommen. Die resultierenden Systemparameter sind in Tabelle 4.1 aufgeführt.

Tabelle 4.1: Parameter des vereinfachten Systemmodells.

Statordurchmesser	D_{Stator}	189 mm
Statorlänge	l_{Stator}	275 mm
Wärmekapazität Motor	C_M	24500 J/K
Wärmeübergangskoeffizient	α	1900 $\frac{\text{W}}{\text{m}^2\text{K}}$ (nach (BLH17))
spez. Wärmekap. Kühlmittel	$c_{p,KM}$	3341 $\frac{\text{J}}{\text{kg K}}$ (nach (Pol14))
Wärmekapazität Kühlmittel	C_{KM}	35000 J/K

Das Kühlsystem wird exemplarisch auf eine konstante Belastung mit 100 kW Motorleistung bei 70 km/h Fahrgeschwindigkeit und 40°C Umgebungstemperatur ausgelegt ($\vartheta_M < 90^\circ\text{C}$). Der Leistungsbedarf des Kühlsystems ist von der Leistung der Kühlmittelpumpe und der Lüfterleistung abhängig. Sowohl die benötigte Pumpenleistung als auch die Lüfterleistung hängen dabei näherungsweise kubisch vom Kühlmittelvolumenstrom bzw. Luftmassenstrom ab (Tao16). Für einen gegebenen Sollwärmestrom \dot{Q}_L an die Umgebung kann die verbrauchsminimale Kombination aus Kühlmittelvolumenstrom und Luftmassenstrom ermittelt werden (Aue15). Die maximale Leistungsaufnahme der Pumpe wird im Folgenden mit 300 W bei maximalem Kühlmittelstrom (0.5kg/s) angenommen, die maximale Lüfterleistung mit 800 W. Die Erhöhung des Abwärmestroms durch den Lüfterbetrieb nimmt mit zunehmender Fahrgeschwindigkeit ab (vgl. (AGJ03)). Abbildung 4.16(a) zeigt das dimensionierte Kühlerkennfeld mit spez. Wärmeleistung über den Masseströmen von Kühlluft und Kühlmittel. Abbildung 4.16(b) zeigt die zugehörige Leistungsaufnahme P_K von Lüfter und Kühlmittelpumpe bei optimaler Wahl des Betriebspunktes für eine geforderte spezifische Wärmeleistung \dot{q}_L bei Fahrgeschwindigkeit v .

4.3.2 Modellprädiktive Regelung der Motortemperatur

Das im vorherigen Abschnitt beschriebene System lässt sich als Regelsystem mit zwei Zustandsgrößen beschreiben, wobei die Zustände durch

$$x_1 = \vartheta_{KM}, x_2 = \vartheta_M \quad (4.19)$$

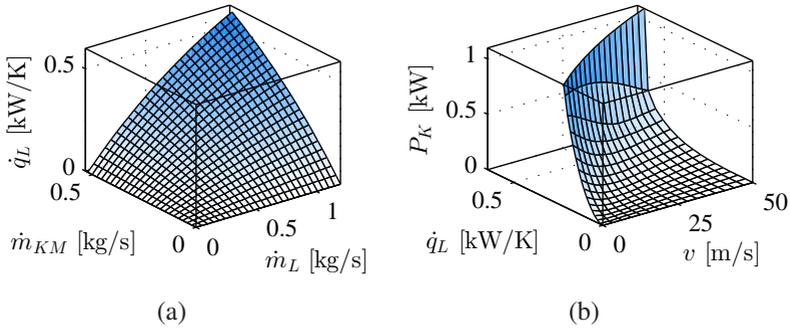


Abb. 4.16: (a) Kühlerkennfeld der spezifischen Wärmeleistung \dot{q}_L über Massenströme von Kühlmittel \dot{m}_{KM} und Kühlluft \dot{m}_L . (b) Kombiniertes Leistungsbedarf P_K von Lüfter und Kühlmittelpumpe bei geforderter spez. Wärmeleistung \dot{q}_L und Fahrgeschwindigkeit v .

gegeben sind und somit folgende Differentialgleichung für die Systemzustände gilt:

$$\begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \end{bmatrix} = \begin{bmatrix} \dot{\vartheta}_{KM} \\ \dot{\vartheta}_M \end{bmatrix} = \begin{bmatrix} \frac{1}{C_{KM}} (\dot{Q}_{M,KM} - \dot{Q}_L) \\ \frac{1}{C_M} (\dot{Q}_V - \dot{Q}_{M,KM}) \end{bmatrix}, \quad (4.20)$$

wobei die beiden Systemzustände über den Wärmestrom $\dot{Q}_{M,KM}$ gekoppelt sind. Gleichung 4.20 lässt sich in eine zeitdiskrete Übertragungsfunktion f_s umwandeln, mit

$$\begin{aligned} x_{t+1} = \begin{bmatrix} x_{1,t+1} \\ x_{2,t+1} \end{bmatrix} &= \begin{bmatrix} x_{1,t} \\ x_{2,t} \end{bmatrix} + \Delta t \cdot \begin{bmatrix} \frac{1}{C_{KM}} (\dot{Q}_{M,KM} - \dot{Q}_L) \\ \frac{1}{C_M} (\dot{Q}_V - \dot{Q}_{M,KM}) \end{bmatrix} \\ &= f_s(x_t, u_t, y_t). \end{aligned} \quad (4.21)$$

Stellgröße und Zielfunktion

Für die optimalsteuerungsbasierte Regelung sollte eine Eingangsgröße gewählt werden, die sich möglichst gut für eine Diskretisierung des Suchraums eignet. In diesem Fall bietet sich die, an die Umgebung abzuführende spezifische Wärmeleistung an, da sie die Auslastung des Kühlsystems unabhängig vom

Umgebungs- und Systemzustand beschreibt. Für das Optimalsteuerungsproblem gilt somit

$$u = \dot{q}_L . \quad (4.22)$$

Weiterhin muss eine Zielfunktion definiert werden, die das Sollverhalten des Systems beschreibt. Dabei sollen die im vorherigen Abschnitt beschriebenen Anforderungen berücksichtigt werden. Die erste Anforderung ist die Verbrauchsminimierung. Hierfür ist sowohl das temperaturabhängige Wirkungsgradverhalten der elektrischen Maschine als auch der Leistungsbedarf durch das Kühlsystem zu berücksichtigen. In den Untersuchungen von (Aue15) wurde für eine ASM in den meisten Fahrzyklen eine hohe mittlere Temperatur als vorteilhaft ermittelt. Da die Eisenverluste in einer PSM eine noch größere Rolle als bei der ASM spielen und damit die Verlustreduktion bei höherer Temperatur noch größer ist (vgl. (SH13)), kann dies uneingeschränkt auf eine PSM übertragen werden. Aus Sicht der Effizienzanforderung ist somit eine hohe Motortemperatur anzustreben.

Als Zielfunktion lässt sich – entsprechend der Folgerungen in (Aue15) – ableiten, dass der Motor bei der größtmöglichen Temperatur unter Einhaltung der thermischen Grenzen betrieben werden sollte. Dieses Sollverhalten wird im Folgenden durch eine Kostenfunktion

$$J(x, u, y) = J_x(x_2) + f_u \cdot J_u(x, u, y) \quad (4.23)$$

abgebildet, wobei J_x die von der Motortemperatur abhängigen Zustandskosten sind und J_u die Kosten für den Kühlleistungsbedarf J_u mit einem Gewichtungsfaktor f_u . Im Folgenden wird eine Motortemperatur von $x_2 = 90^\circ\text{C}$ als optimale Betriebstemperatur angenommen. Die Kosten J_x für eine Abweichung werden asymmetrisch (Unterschreitung der Temperatur weniger kritisch gewertet als Überschreitung) mit quadratischem Verlauf definiert (siehe Abb. 4.17). Die Kosten für den Stellaufwand werden über die erforderliche Kühlleistung P_K bewertet (normiert auf eine Referenzleistung $P_{K,norm}$). Um den geforderten Abwärmestrom und damit die geforderte Pumpen- bzw. Lüfterdrehzahl möglichst konstant zu halten wird ein zusätzlicher Kostenterm J_{u_0} für Wechsel von u

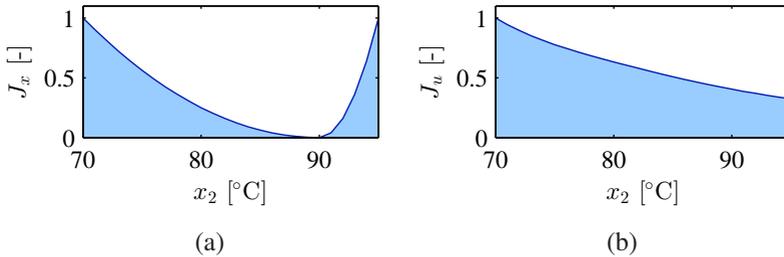


Abb. 4.17: Zustandskosten J_x über Motortemperatur x_2 (a) und Kühlleistungs-Kosten J_u bei stationär eingeregelter Motortemperatur für einen beispielhaften Betriebspunkt (b).

hinzugefügt (entsprechend Verstellkosten im Beispiel Aerodynamik). Damit ergeben sich die Verstellkosten zu

$$J_u(x, u, y) = \frac{P_K(x_1, v, \dot{q}_L)}{P_{K,norm}} + \delta_u \cdot J_{u0}, \quad \delta_u = \begin{cases} 1 & \text{falls } u_t \neq u_{t-1} \\ 0 & \text{sonst} \end{cases} \quad (4.24)$$

Der Faktor f_u und die Referenzleistung $P_{K,norm}$ gewichten die einzusetzende Kühlleistung gegen auftretende Temperaturabweichungen von der Optimaltemperatur. Für $f_u = 0$ wird die erforderliche Kühlleistung ignoriert und nur der temperaturabhängige Anteil der Kosten berücksichtigt. Das System versucht in diesem Fall unter maximalem Einsatz der verfügbaren Kühlleistung die Motortemperatur so genau wie möglich auf die Optimaltemperatur einzuregulieren. Für $f_u > 0$ wird ein Kompromiss aus eingesetzter Kühlleistung und Temperaturabweichung angestrebt.

PI-Regler: Als Referenz für eine nicht vorausschauende Regelung wird ein PI-Regler eingesetzt. Dabei wird der an die Umgebung abzuführende Wärmestrom \dot{Q}_L als Steuergröße u verwendet. Für den Regler gilt somit

$$u_{PI} = \dot{Q}_L = k_P(x_2 - \vartheta_{soll}) + k_I \int_0^t (x_2(\tau) - \vartheta_{soll}) \, d\tau \quad (4.25)$$

mit der Motorsolltemperatur ϑ_{soll} .

Lösung des Optimalsteuerungsproblems

Sei $\mathcal{X}_k \subset \mathbb{R}$ der zulässige Wertebereich des Systemzustands und \mathcal{U}_d die diskrete und endliche Menge aller zulässigen Steuergrößen.

Wenn sich beim betrachteten System der Einfluss der Umgebungsgröße nicht auf die Zustandswechsel des Systems auswirkt, kann das Optimierungsproblem z.B. durch Diskretisierung des Wertebereichs des kontinuierlichen Systemzustands vereinfacht werden (siehe z.B. (Wah15, Rad13)). Damit kann das System wieder als ein System mit diskreten Zuständen behandelt und das Lösungsverfahren aus Abschnitt 4.2.1 entsprechend angewendet werden.

Hat die Umgebungsgröße Einfluss auf die Systemübertragungsfunktion ($f_s = f(y)$), wie es bei dem hier betrachteten System der Fall ist, muss im Optimalsteuerungsproblem mit einer Zustandsverteilung X gerechnet werden:

$$X_{\bar{t}} = f_s(X_{\bar{t}-1}, u_{\bar{t}-1}, \hat{Y}_{\bar{t}-1}), u \in \mathcal{U}_d, x \in \mathcal{X}_k. \quad (4.26)$$

Da der Systemzustand zu einem Zeitpunkt \bar{t} damit durch eine Wahrscheinlichkeitsverteilung $X_{\bar{t}}$ repräsentiert ist, kann der Zustandsraum nicht ohne Weiteres diskretisiert werden. Darüber hinaus ist für eine stochastische Vorhersage des Systemverhaltens auch die Verwendung einer Steuertrajektorie u als Optimierungsvariable nicht ausreichend. Vielmehr muss die Optimierungsvariable in diesem Fall ebenfalls eine Regelstrategie π (engl.: control policy) sein, z.B. in Form einer Folge von Regelgesetzen $v_{\bar{t}}(\cdot)$:

$$\pi = \{v_0(\cdot), v_1(\cdot), \dots, v_{T-1}(\cdot)\}. \quad (4.27)$$

Diese Verfahrensweise wird auch als Closed-Loop SMPC bezeichnet, da in diesem Fall eine explizite Rückführung der Störung innerhalb des Optimierungshorizonts berücksichtigt wird. Die Bestimmung einer solchen optimalen Regelstrategie π^* kann aus praktischen Gesichtspunkten aber häufig nicht erfolgen. (May14)

Wird das Optimierungsproblem dennoch mit einer Steuertrajektorie als Entscheidungsvariablen gelöst, spricht man auch von Open-Loop SMPC. Die Anwendung dieser (Open-Loop) Steuertrajektorie kann jedoch zu abweichendem (suboptimalem) Verhalten im geschlossenen Regelkreis führen. Da sich im Optimierungsproblem aus der Steuertrajektorie eine Verteilung möglicher

Zustände X ergibt, kann die Anwendung im geschlossenen Regelkreis zu einer unnötig konservativen Zustandstrajektorie führen (Wei09). Unter gewissen Voraussetzungen (z.B. signifikantes Messrauschen) kann diese Open-Loop Steuertrajektorie aber zu besseren Resultaten als eine Closed-Loop Steuerstrategie führen (Wei09). Weiterhin ist die Open-Loop Strategie praktikabel, wenn die Streuung des Zustands verhältnismäßig klein ist (stabiles Systemverhalten) und keine Zustandsbeschränkungen vorliegen (May14). Im Folgenden wird daher die Lösung des Optimalsteuerungsproblems über eine Steuertrajektorie \underline{u} beschrieben.

Zur exakten Lösung des stochastischen Optimalsteuerungsproblems aus Gl. (4.1) muss ein T -schrittiger Suchbaum über die möglichen Steuerwerte durchsucht werden. Dabei ergibt sich ein exponentieller Zusammenhang zwischen der Mächtigkeit der Steuermenge \mathcal{U}_d und der Anzahl der Suchknoten mit $\sum_{t=1}^T |\mathcal{U}_d|^t$. Eine effiziente Strategie zur Auswertung des Suchbaums, die das Auffinden der optimalen Lösung garantiert, ist die Uniform-Cost-Search (UCS).

Uniform-Cost-Search: UCS ist eine einfache Strategie, den optimalen Pfad eines Suchbaums zu finden. Ausgehend vom Startknoten des Suchbaums (x_0), werden alle möglichen Nachfolger der offenen Liste hinzugefügt und deren Pfadkosten V_i ermittelt. Anschließend wird jeweils der Knoten expandiert, der die geringsten Pfadkosten aufweist und die möglichen Nachfolger dieses Knotens werden der offenen Liste hinzugefügt. Expandierte Knoten werden aus der offenen Liste entfernt. Der optimale Pfad mit minimalen Kosten ist gefunden, sobald ein Knoten der letzten Suchebene ($\bar{t} = T$) expandiert wurde. Die Komplexität der Uniform-Cost-Search ist dabei von der Struktur der Kostenfunktion abhängig. Im schlechtesten Fall werden alle Knoten expandiert und der gesamte Suchbaum muss durchlaufen werden. Im besten Fall wird aber nur der optimale Pfad expandiert. Siehe hierzu z.B. (RN09). Somit garantiert UCS zwar die Optimalität der gefundenen Lösung, der benötigte Rechenaufwand ist aber stark von den Eigenschaften des Systems und den Randbedingungen abhängig.

Heuristische Uniform-Cost-Search: In (Wah15) wird ein heuristisches Prinzip zur Reduktion des Suchraums für kontinuierlichwertige Systemzustände mit dynamischer Programmierung beschrieben. Eine ähnliche Heuristik lässt sich auch in die steuergroßenorientierte Formulierung der Uniform-Cost-Search übertragen. Da für die Systemübertragungsfunktion die Markov-Eigenschaft

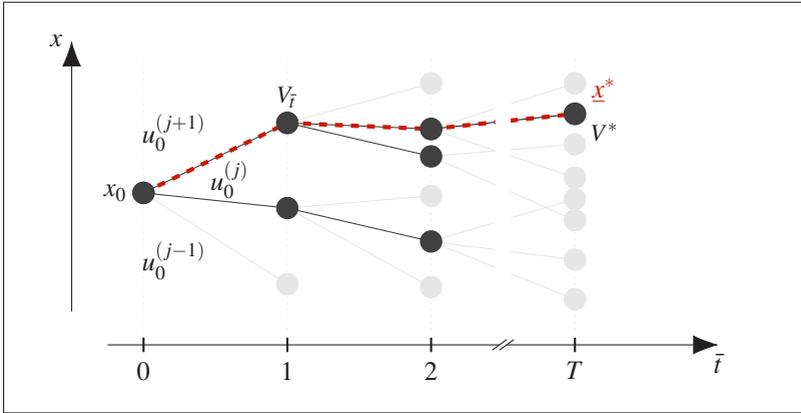


Abb. 4.18: Schematische Darstellung des Suchraums der Uniform-Cost-Search (expandierte Knoten in schwarz) über einen Optimierungshorizont T mit Startzustand x_0 , Steuergröße u und optimalem Zustandsverlauf \underline{x}^* mit Kosten V^* .

vorausgesetzt wurde, kann unter Annahme einer lokalen Konvexität der Kostenfunktion eine Bevorzugung von lokal optimalen Zuständen zur Reduktion des Suchraums eingesetzt werden.

Um diese lokale Konvexität auszunutzen, wird der zulässige Zustandsraum in N_m Bereiche aufgeteilt und jeweils nur der in diesem Bereich beste Zustand weiterverfolgt. Die heuristisch beschränkte Suche lässt sich dann wie folgt formulieren: Sei

$$\mathcal{X}_m \subset \mathcal{X}_k, m \in [1, N_m], \quad (4.28)$$

eine Aufteilung des Zustandsraums \mathcal{X}_k in N_m Submengen, dann wird jeweils nur die Expansion eines Knotens aus der Submenge \mathcal{X}_m zugelassen. Für eine deterministische Vorhersage \hat{y} ist dem Suchknoten ein Zustand x zugeordnet. Der Zustand x wird der Submenge m zugeordnet, wenn $x \in \mathcal{X}_m$ gilt. Wird eine stochastische Vorhersage \hat{Y} verwendet, ist dem Knoten eine Sample-Verteilung X zugeordnet. Die Submenge wird dann über den Erwartungswert bestimmt. Für die Zuordnung gilt somit

$$X \mapsto m : \mathbb{E}(X) \in \mathcal{X}_m. \quad (4.29)$$

Bei ausreichend feiner Diskretisierung N_m kann für lokal konvexe Kostenfunktionen so eine deutliche Reduktion des Suchraums erreicht werden. Dabei wird die maximale Anzahl an expandierten Knoten durch die Heuristik auf $N_m \cdot T$ begrenzt, womit eine lineare Abhängigkeit der Suchknoten von der Anzahl der Zeitschritte des Optimierungsproblems existiert. Dieses Verfahren wird im Folgenden als Heuristic-Uniform-Cost-Search (HUCS) bezeichnet. Der Suchraum von HUCS ist in Abb. 4.19 schematisch dargestellt.

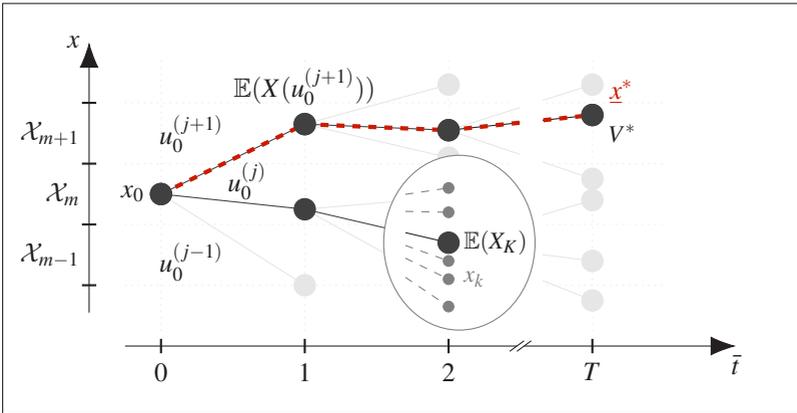


Abb. 4.19: Schematische Darstellung des Suchraums der heuristischen Uniform-Cost-Search für ein System mit unsicheren Zustandsübergängen. x_0 : Startzustand; u : Stellgröße; \mathcal{X}_m : heuristische Diskretisierung des Zustandsraums; x_k : Sample k einer Zustandsverteilung; $\mathbb{E}(X_K)$: Erwartungswert einer Zustandsverteilung aus K Samples; x^* : Optimaler Zustandsverlauf mit Kosten V^* .

Da UCS nur begrenzt für echtzeitfähige Anwendungen in Betracht kommt, wird für das vorausschauende Thermomanagement die heuristische Einschränkung des Suchraums angewendet. Dafür wird der Zustandsraum in N_m Bereiche aufgeteilt. Da das System zwei Zustandsvariablen hat, wird für jeden dieser Zustände eine Diskretisierung eingesetzt: Seien $\mathcal{X}_{1,m}$ und $\mathcal{X}_{2,m}$ Submengen des erreichbaren Zustandsraums mit

$$\begin{aligned}
 \mathcal{X}_{1,m} &\subset \mathcal{X}_{1,k}, \quad m \in [1, N_{m_1}] \\
 \mathcal{X}_{2,n} &\subset \mathcal{X}_{2,k}, \quad n \in [1, N_{m_2}] \\
 \text{mit } x_1 &\in \mathcal{X}_{1,k}, \quad x_2 \in \mathcal{X}_{2,k},
 \end{aligned}
 \tag{4.30}$$

eine Aufteilung des Zustandsraums in $N_{m_1} \times N_{m_2}$ Submengen, dann wird jeweils nur die Expansion eines Knotens im Zustandsraum $X_{1,m} \times X_{2,n}$ zugelassen. Dabei gilt für die Zuordnung der Submengen

$$x \mapsto [m, n] : x_1 \in \mathcal{X}_{1,m}, x_2 \in \mathcal{X}_{2,n} \quad (4.31)$$

bei deterministischem Zustand x bzw.

$$X \mapsto [m, n] : \mathbb{E}(x_1) \in \mathcal{X}_{1,m}, \mathbb{E}(x_2) \in \mathcal{X}_{2,n} \quad (4.32)$$

bei einer Zustandsverteilung X .

Abbildung 4.20 zeigt die resultierenden Suchräume mit UCS und HUCS für eine beispielhafte Situation, wobei $N_{m_1}, N_{m_2} = 5$ gewählt wurde. Der Suchbaum ist für $T = 15$ Zeitschritte dargestellt. Die optimierten Zustandsverläufe \underline{x}^* sind für beide Verfahren fast identisch. Da HUCS aber nicht die Optimalität der Lösung garantiert, unterscheiden sich die resultierenden Steuer- und Zustandsverläufe geringfügig. Die Anzahl der ausgewerteten Suchknoten ist bei Einsatz der Heuristik signifikant kleiner (189 Auswertungen für HUCS gegenüber 3283 für UCS).

4.3.3 Vergleich PI-Regler und MPC

Um den Unterschied zwischen vorausschauender (MPC) und konventioneller Regelung (PI) zu verdeutlichen, wird zunächst das Regelverhalten von MPC mit idealer Vorausschau (Vorausschauhorizont $T = 30s$) und möglichen Konfiguration des PI-Reglers verglichen. Hierfür werden die Reglerparameter k_P und k_I systematisch variiert, um die realisierbaren Zielerreichungen der nicht vorausschauenden Regelung zu analysieren. Für eine Fahrt werden die jeweiligen Zielerreichungen bezüglich der Zustands- und der Stellkosten ermittelt (R_x bzw. R_u), mit

$$\begin{aligned} R_x &= \sum_{t=0}^N J_x(x_t), \\ R_u &= \sum_{t=0}^N J_u(x_t, u_t, y_t). \end{aligned} \quad (4.33)$$

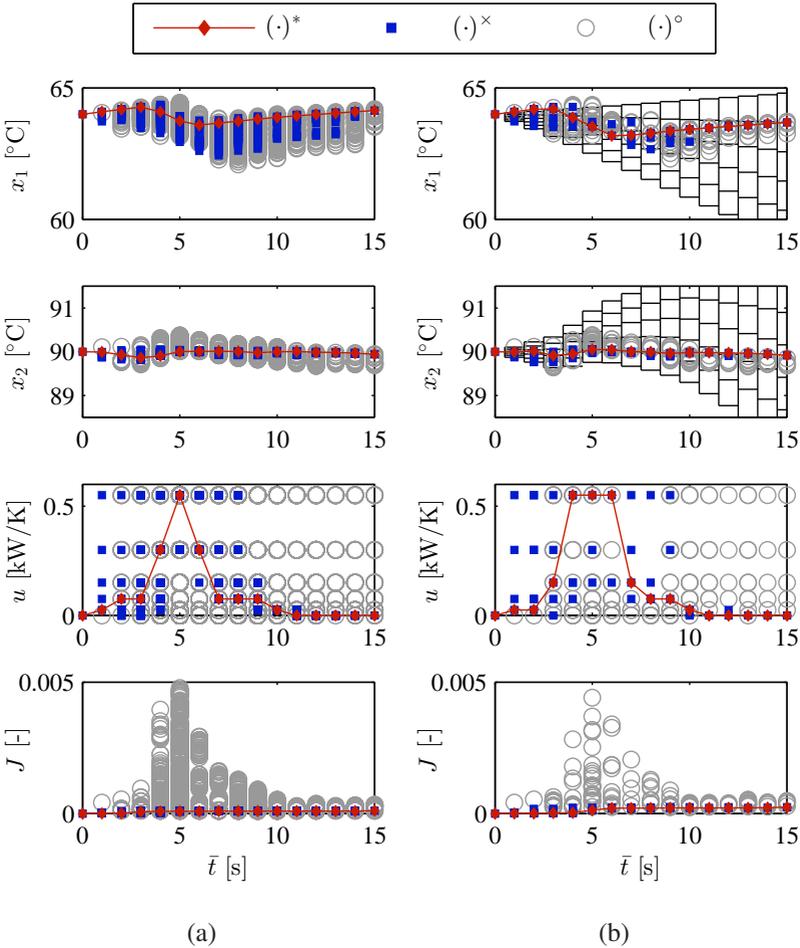


Abb. 4.20: Resultierender Steuervektor \underline{u} , Verlauf von Kühlmitteltemperatur x_1 und Motortemperatur x_2 für den Suchraum bei Verwendung von UCS (a) und der heuristisch eingeschränkten Suche mit HUCS (b). $(\cdot)^*$: Bester gefundener Pfad; $(\cdot)^\times$: Expandierte Knoten; $(\cdot)^\circ$: Knoten der offenen Liste.

Abb. 4.21 zeigt diese Zielerreichungen für die vorausschauende Regelung mit idealer Vorhersage gegen die möglichen paretooptimalen Konfigurationen des PI-Reglers für einen dynamischen Fahrer (a) und einen ruhigen Fahrer (b).

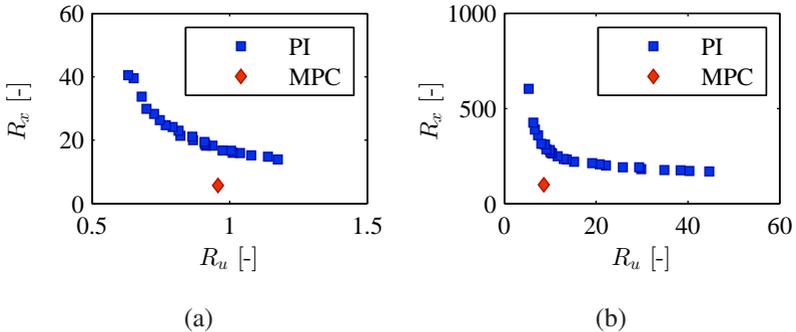


Abb. 4.21: Pareto-Front der erzielbaren Regelgüte (Zielerreichung für Zustandskosten R_x über Stellkosten R_u) mit unterschiedlichen Konfigurationen des PI-Reglers und MPC (Vernachlässigung der diskreten Wechselkosten J_{u_0} für Vergleichbarkeit) bei idealer Vorhersage für Fahrer A (a) und B (b).

Der Regelaufwand ($R_x + R_u$) ist offensichtlich von der Fahrweise abhängig und für den dynamischen Fahrer deutlich höher. In beiden Fällen zeigt sich aber, dass die vorausschauende Regelung eine bessere kombinierte Zielerreichung ermöglicht, als durch Variation der PI-Regelparameter möglich ist. Dies verdeutlicht, dass durch den MPC-Ansatz eine geringere Regelabweichung (R_x) unter geringerem Regelaufwand (R_u) erreichbar ist.

Abbildung 4.22 zeigt den Vergleich der Zustands- und Regelgrößen für den dynamischen Fahrer. Durch die sprunghaften Anstiege in der Leistungsanforderung kommt es zu einem ebenso sprunghaften Anstieg des Wärmeeintrags in das Kühlsystem. Der PI-Regler erhöht die auszukoppelnde Wärmeleistung erst nach einer steigenden Abweichung der Motortemperatur x_2 , was zu deutlichen Temperaturspitzen führt. Mit der vorausschauenden Regelung wird bei relevanten Leistungsphasen bereits vor oder zu Beginn der Leistungsanforderung die Wärmeauskopplung erhöht, um dem bevorstehenden Temperaturanstieg entgegenzuwirken. Die Spitzentemperaturen können dadurch entsprechend reduziert werden.

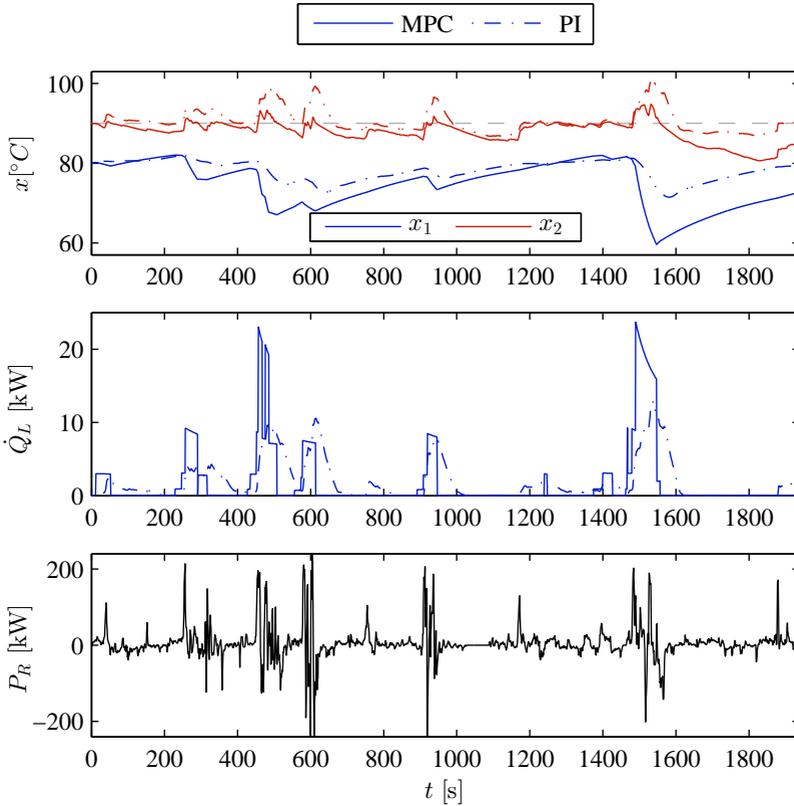


Abb. 4.22: Temperaturverläufe von Kühlmittel x_1 und Motor x_2 für die Regelung mit dem MPC-Ansatz (ideale Vorhersage) und dem PI-Regler bei einem dynamischen Fahrer.

Abb. 4.23 zeigt die entsprechenden Zustände für den ruhigen Fahrer. Hier zeigen sich ähnliche Charakteristiken wie bei dem dynamischen Fahrer. Durch die deutlich weniger dynamischen Leistungsanforderungen sind die auftretenden Temperaturschwankungen aber deutlich geringer ausgeprägt. Die Motortemperatur kann somit von beiden Verfahren mit geringerer Abweichung von der Idealtemperatur ($x_2 = 90^\circ\text{C}$) geregelt werden.

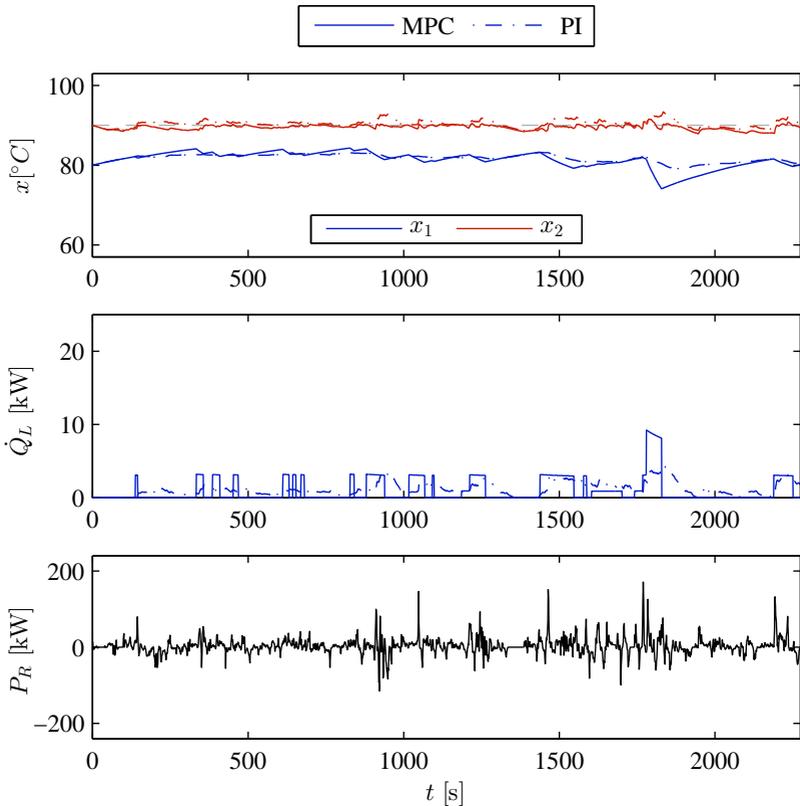


Abb. 4.23: Temperaturverläufe von Kühlmittel x_1 und Motor x_2 für die Regelung mit dem MPC-Ansatz (ideale Vorhersage) und dem PI-Regler bei einem ruhigen Fahrer.

Diese Beispiele zeigen, dass die nicht vorausschauende Regelung deutlich schlechter auf sprunghafte Wechsel in der Leistungsanforderung reagieren kann, wodurch ungewollte Temperaturspitzen oder unnötig hoher Kühlaufwand entstehen können. Mit vorausschauender Regelung kann mit vergleichsweise geringem Kühlaufwand eine geringere Regelabweichung erzielt werden. Wie die vorausschauende Regelung mit realen statt der idealen Vorhersage reagiert, wird im nächsten Abschnitt behandelt.

4.3.4 Ergebnisse mit Realfahrten

Nachdem zuvor die ideale Vorhersage zur Bestimmung der Lösung des Optimalsteuerungsproblems verwendet wurde, werden im Folgenden die Resultate mit den behandelten Vorhersagemodellen SP_{mc} , SP_p und MK für alle Fahrten ermittelt. Die zugehörigen Zustandsverläufe werden erneut mit $x_{SP_{mc}}$, x_{SP_p} , $x_{SP_{MK}}$ und $u_{SP_{mc}}$, u_{SP_p} , $u_{SP_{MK}}$ bezeichnet, die Regelgüte entsprechend mit $R_{SP_{mc}}$, R_{SP_p} und R_{MK} . Die Vorhersagen werden entsprechend Abschnitt 3.8.4 mit einem Initialisierungslauf zur Parameterschätzung, einer Sample-Größe $K = 10$ und einem Vorausschauhorizont von $T = 30s$ berechnet.

Bekannte Strecke: Zunächst wird von einer bekannten Routenführung für die auf Streckendaten basierenden Modelle ausgegangen. Abbildung 4.24 zeigt die mittlere Regelgüte sowie die Verteilung über alle Fahrer (normiert auf die mittlere Regelgüte \bar{R}_{opt}). Die beiden auf Streckendaten basierenden Modelle erzielen eine vergleichbare Regelgüte, die vergleichsweise wenig von der Regelgüte mit idealer Vorhersage abweicht. Die Markov-Kette schneidet signifikant schlechter ab.

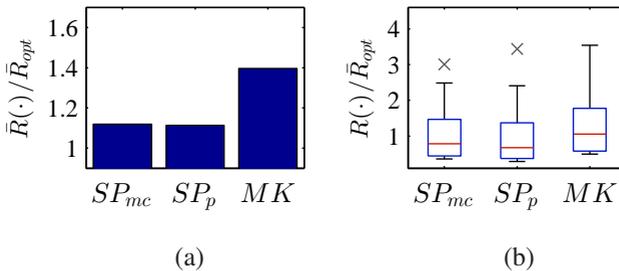


Abb. 4.24: Erzielte Regelgüte (normiert auf die mittlere optimale Regelgüte \bar{R}_{opt}) für die unterschiedlichen Vorhersagemodelle, gemittelt über alle Fahrer. (a) Mittlere Regelgüte \bar{R} , (b) Box-Whisker-Plot von R mit Median, Interquartilbox und Maximal- bzw. Minimalwerten.

Abbildung 4.25 zeigt die Verteilung der erzielten Zustandskosten R_x und Stelllaufwände R_u für alle Fahrer und Vorhersagemodelle. Die Darstellung zeigt, dass die erzielten Zustandskosten für die Vorhersagemodelle vergleichbar sind. Die schlechtere Regelgüte mit den Vorhersagen der Markov-Kette resultiert folglich aus dem deutlich höheren Stelllaufwand R_u . Der Nachteil der weniger

scharfen Vorhersagen resultiert vor allem in einem höheren Stellaufwand zur Erreichung des Regelziels. Weiterhin zeigen sich geringfügig höhere Stellkosten

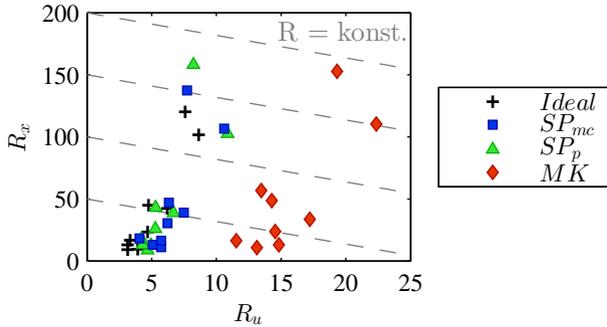


Abb. 4.25: Für die jeweiligen Testfahrten erzielten Zustandkosten J_x über Verstellkosten J_u für die unterschiedlichen Vorhersagemodelle.

R_u für die stochastische Vorhersage SP_{mc} im Vergleich zur Punktvorhersage SP_p . Dies entspricht dem erwarteten Verhalten der Open-Loop Lösung des stochastischen Optimalsteuerungsproblems im geschlossenen Regelkreis (siehe auch (Wei09)). Durch die Open-Loop Lösung kommt es zu einer Überschätzung der Unsicherheit in den resultierenden Systemzuständen x , was in einer tendenziell zu hohen Temperaturreserve und damit einem leicht erhöhten Kühlaufwand resultiert. Bei der Punktvorhersage SP_p tritt dieser Effekt nicht auf. Durch im Mittel etwas geringere Zustandkosten ist die mittlere Zielerreichung für SP_p und SP_{mc} aber fast identisch. Eine Closed-Loop Lösung des stochastischen Optimalsteuerungsproblems würde hier eventuell besser abschneiden und die Regelgüte für SP_{mc} gegenüber SP_p verbessern, kann aber nicht ohne weiteres ermittelt werden.

Die resultierenden Systemzustände für eine beispielhafte Autobahnauffahrt sind in Abbildung 4.26 für die Vorhersagemodelle SP_{mc} und MK dargestellt. Der Vergleich des abgeführten Wärmestroms \dot{Q}_L zeigt, dass mit der auf Streckendaten basierenden Vorhersage bereits vor der Beschleunigungsphase Wärme aus dem System abgeführt wird, um die Motortemperatur x_2 abzusenken. Mit der Markov-Kette wird die Temperatur in dieser Phase konstant gehalten. Bei Eintritt der Radleistungsforderung ($t \approx 1615$ s) kann durch die Absenkung

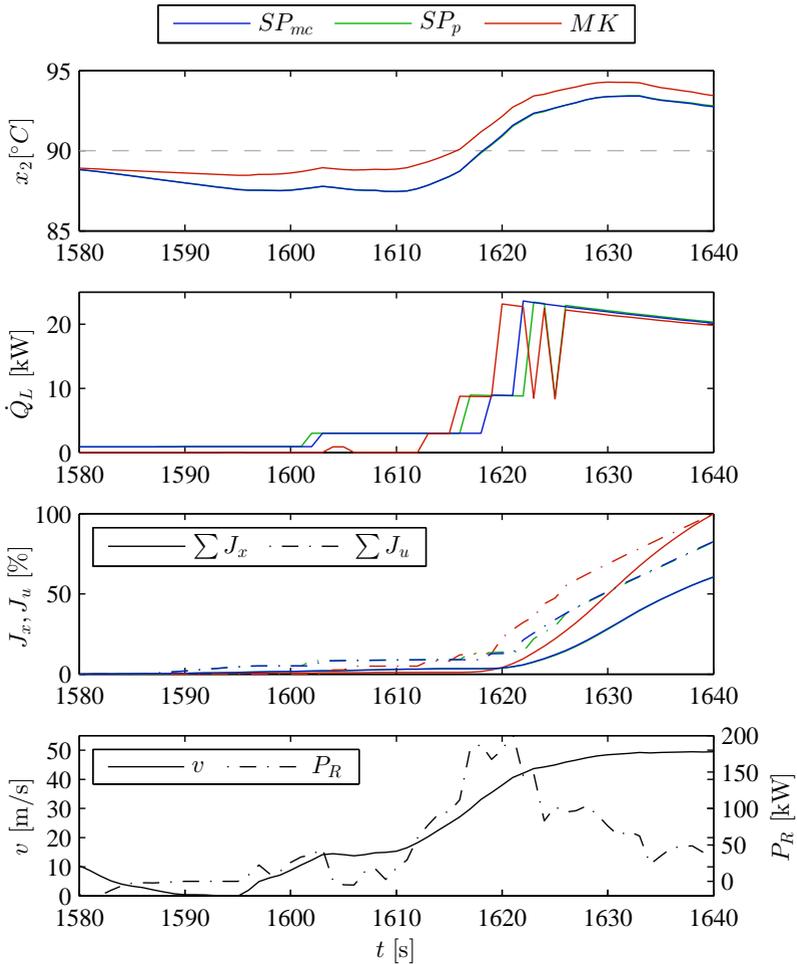


Abb. 4.26: Verläufe von Motortemperatur x_2 , Wärmestrom \dot{Q}_L , kumulierte Gütemaße J_x und J_u (normiert auf den jeweiligen Endwert mit der Vorhersage MK) sowie Geschwindigkeit v und Radleistung P_R für eine beispielhafte Autobahnauffahrt. Die Zustandsverläufe sind jeweils bei Verwendung der Vorhersagen SP_{mc} (blau), SP_p (grün) und MK (rot) dargestellt (bekannte Strecke für SP_{mc} und SP_p).

der notwendige Stellaufwand reduziert und die auftretende Temperaturspitze verringert werden. Die kumulierten Gütemaße J_x und J_u (normiert auf den jeweiligen Endwert mit der Vorhersage MK) zeigen, dass bei Verwendung von SP_{mc} eine bessere Zielerreichung für diese Situation realisiert werden kann. Bei Verwendung der Punktvorhersage SP_p entspricht das Verhalten in diesem Fall im Wesentlichen dem bei Verwendung der Verteilungsvorhersage SP_{mc} . Die resultierenden Strategien und Zustandsverläufe unterscheiden sich nur marginal.

Unbekannte Strecke: Wie im vorangegangenen Beispiel werden auch für das Thermomanagement die Ergebnisse mit unbekannter Routenföhrung für die auf Streckendaten basierenden Modelle berechnet. Abbildung 4.27 zeigt den Vergleich für eine Beispielsituation bei Verwendung der stochastischen Vorhersage SP_{mc} und der Punktvorhersage SP_p . Die Situation zeigt, dass die Punktvorhersage ohne Kenntnis der Strecke den bevorstehenden Leistungseintrag später erfasst und im System so höhere Spitzentemperaturen auftreten, als bei Verwendung der Verteilungsvorhersage.

Bei Betrachtung der mittleren Regelgüte über alle Fahrer (Abbildung 4.28) bestätigt sich dieser Zusammenhang. Die erzielte Regelgüte verschlechtert sich zwar für beide Vorhersagemodelle, im Vergleich zu den Ergebnissen bei bekannter Strecke. Für die Punktvorhersage nimmt die Regelgüte jedoch stärker ab. Die stochastische Vorhersage schneidet in Summe besser ab. In Abb. 4.29 ist zusätzlich die Verteilung der Stell- und Zustandskosten R_u und R_x für die einzelnen Fahrer dargestellt. Diese Darstellung zeigt nochmals, dass die Verschlechterung der Punktvorhersage vor allem auf den Fahrten mit hohem Regelaufwand ($R = R_x + R_u$) basiert. Im Fall der unbekannteren Strecke überwiegen somit die Vorteile der stochastischen Vorhersage, die auch mehrere Routenverlaufsoptionen in die Strategie mit einbeziehen kann, während die Punktvorhersage sich für eine Verlaufsoption entscheiden muss.

4.3.5 Fazit

Das Systembeispiel des vorausschauenden Thermomanagements einer elektrischen Maschine bestätigt ebenfalls die Überlegenheit der auf Streckendaten basierenden Vorhersagemodelle gegenüber der reinen Zeitreihenmodellierung. Unter den auf Streckendaten basierenden Vorhersagen schneidet die stochasti-

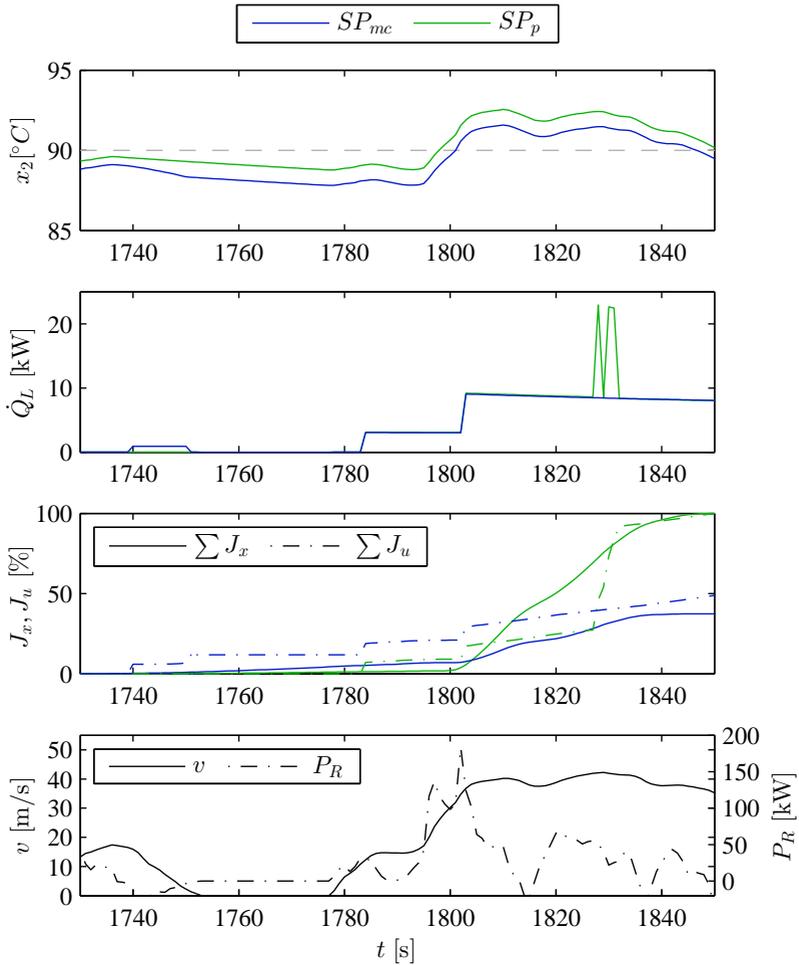


Abb. 4.27: Verläufe von Motortemperatur x_2 , Wärmestrom \dot{Q}_L , kumulierte Gütemaße J_x und J_u (normiert auf den jeweiligen Endwert mit der Vorhersage SP_p) sowie Geschwindigkeit v und Radleistung P_R für eine beispielhafte Autobahnauffahrt. Die Zustandsverläufe sind jeweils bei Verwendung der Vorhersagen SP_{mc} (blau), SP_p (grün) ohne Kenntnis der Route dargestellt.

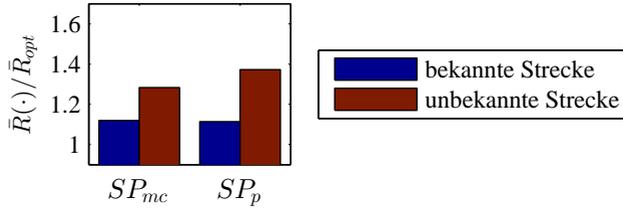


Abb. 4.28: Erzielte mittlere Regelgüte \bar{R} (normiert auf mittlere optimale Regelgüte \bar{R}_{opt}) für die auf Streckendaten basierenden Vorhersagemodelle bei bekannter und unbekannter Strecke, gemittelt über alle Fahrer.

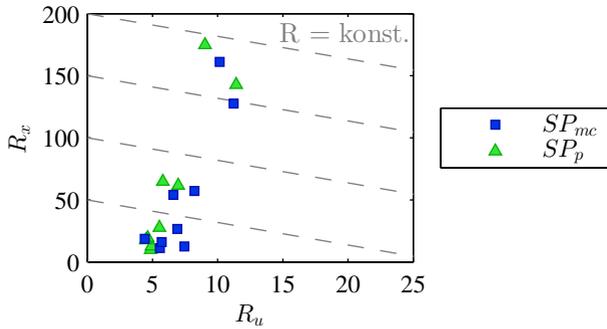


Abb. 4.29: Für die jeweiligen Testfahrten erzielte Regelgüte für Zustandskosten R_x über Verstellkosten R_u für die auf Streckendaten basierenden Modelle bei unbekannter Routenführung.

sche Vorhersage SP_{mc} auch für dieses Systembeispiel besser ab als die Punktvorhersage SP_p , insbesondere wenn die Fahrtstrecke nicht im voraus bekannt ist. Dabei ist jedoch zu beachten, dass das stochastische Optimalsteuerungsproblem über eine optimale Steuertrajektorie \underline{u}^* gelöst wurde und somit eine Open-Loop-Strategie über den Optimierungshorizont darstellt. Bei Implementierung einer Closed-Loop-Strategie ist tendenziell nochmals eine Verbesserung der Regelstrategie für die Verteilungsvorhersage zu erwarten.

5 Zusammenfassung und Ausblick

Vorausschauende Regelansätze haben das Potential, eine intelligenterere Steuerung von Fahrzeugsystemen bzw. die Darstellung neuer Funktionalitäten für Fahrzeugsysteme zu ermöglichen. Die Vorhersagbarkeit der dafür notwendigen Größen und der Einfluss der Unsicherheit spielen dabei eine wichtige Rolle für die vorausschauende Regelung. In dieser Arbeit wurde das Zusammenspiel von Fahrerverhalten, Vorhersagen und der vorausschauenden Regelung an mehreren Systembeispielen systematisch untersucht. Die Ergebnisse und Implikationen sind im Folgenden nochmals aufgeführt.

Grundsätzlich kommen unterschiedliche Vorhersagemethoden für die Erzeugung der benötigten Information in Frage. Neben klassischen Zeitreihenmodellen ermöglichen die vorhandenen Umfelddaten auch modellbasierte Vorhersagen unter Einbeziehung der Umgebungsinformationen. In dieser Arbeit wurde hierfür eine Methode zur Modellierung des Fahrerverhaltens vorgestellt, die stochastische Vorhersagen basierend auf Streckendaten ermöglicht. Dabei wurden die Online-Schätzung der benötigten Parameter und die Vorhersage der resultierenden Verteilungen mittels Monte-Carlo-Approximation behandelt. Zur Verifizierung und Validierung des Vorhersagemodells wurden sowohl künstlich generierte als auch real aufgezeichnete Daten eingesetzt.

Zur Bewertung der Monte-Carlo-Vorhersagen wurden verschiedene geeignete Bewertungsmetriken ermittelt. Um die Vorhersagegüte des vorgestellten Modells in Relation zu stellen, wurden weitere gängige Methoden zur Erzeugung von Vorhersagen als Referenz eingesetzt.

Die Bewertung der Modelle hat dabei ergeben, dass die auf Zeitreihen basierende Modellierung mit einer Markov-Kette eine leichtere statistische Kalibrierung der Vorhersagen ermöglicht, da die Unsicherheit direkt erfasst werden kann und nicht von einer Modellierung oder Parametrierung abhängt. Diese Art der Modellierung tendiert dabei aber zu unspezifischen und wagen Vorhersagen, die

wenig situationsspezifische Informationen enthalten. Die auf Streckendaten basierenden Modelle haben einen prinzipbedingt höheren Modellierungsaufwand und sind nicht zwangsläufig vollständig (Erfassung aller Einflüsse). Im Gegensatz zu Zeitreihenmodellen sind sie jedoch in der Lage, deutlich informativere und präzisere Vorhersagen zu treffen. Das Einbeziehen von Unsicherheiten hat sich auch bei einer auf Streckendaten basierenden Vorhersage als vorteilhaft erwiesen. Das vorgestellte stochastische Framework konnte insgesamt die besten Vorhersageergebnisse erzielen. Bei der Punktvorhersage mit Streckendaten und der stochastischen Vorhersage mit Zeitreihenmodellierung (Markov-Kette) unterscheiden sich die Resultate je nach angewendeter Bewertungsfunktion (lineare oder quadratische Gewichtung des Fehlers).

Um Verteilungsvorhersagen zur vorausschauenden Steuerung von Systemen einzusetzen, muss ein stochastisches Optimalsteuerungsproblem gelöst werden. In dieser Arbeit wurden Lösungsansätze für ein System mit diskreten Zuständen (Aerodynamik), sowie ein System mit kontinuierlichen Systemzuständen (Thermomanagement) diskutiert. Für das System mit diskreten Zuständen wurde das Problem dabei mit dynamischer Programmierung gelöst. Bei dem System mit kontinuierlichen Systemzuständen wurde eine heuristisch erweiterte Baumsuche angewendet, die die effiziente Lösungsfindung für diesen Fall ermöglicht. Die Lösungsverfahren wurden an den beispielhaften Systemanwendungen in einer Simulation implementiert. Dabei wurden die zuvor behandelten Vorhersagemodelle zur Erzeugung der benötigten Vorausschauinformationen eingesetzt und hinsichtlich ihrer Eignung bewertet.

Die vorgestellte vorausschauende Regelung der aktiven Aerodynamik ermöglicht dabei die Anpassung der Fahreigenschaften nach den Gesichtspunkten des Energieverbrauchs und der fahrdynamischen Anforderungen an die jeweilige Fahrsituation. Es konnte gezeigt werden, dass eine solche fahrsituationsgerechte Steuerung mit einer Trajektorienvorhersage erreicht werden kann. Durch die Berücksichtigung von Unsicherheiten in der Vorhersage und dem Optimalsteuerungsproblem kann dabei eine robuste Regelstrategie umgesetzt werden, während es bei der Anwendung von Punktvorhersagen zu häufigeren Umentscheidungen durch Abweichungen von der Vorhersage kommen kann. Ohne Verwendung von Streckendaten konnte die fahrsituationsgerechte Steuerung nur eingeschränkt erreicht werden, da besonders die Querdynamikeinflüsse nicht mit ausreichendem Reaktionszeit vorhergesagt werden konnten.

Als zweite Systemanwendung wurde das vorausschauende Thermomanagement einer elektrischen Antriebsmaschine vorgestellt. Die vorausschauende Regelung gewährleistet dabei die effiziente Begrenzung der Motortemperatur auf einen vorgegebenen Temperaturbereich unter Berücksichtigung der aktuellen und zukünftigen Umgebungsbedingungen. Temperaturspitzen in der elektrischen Antriebsmaschine können dabei durch ein vorausschauendes Absenken von Motor und Kühlmitteltemperatur vermieden werden.

Für beide Systemanwendungen haben sich die auf Streckendaten basierenden Vorhersagen als geeigneter erwiesen. Die unspezifischen Vorhersagen der Markov-Ketten, wie sie für stochastische MPC in der Literatur häufig eingesetzt wurden, resultierten trotz statistisch besserer Kalibrierung in einigen Fällen in einer nur ungenügenden Zielerreichung der vorausschauenden Regelung. In allen Fällen waren die Ergebnisse schlechter, als bei Verwendung der auf Streckendaten basierenden Modelle. Unter den auf Streckendaten basierenden Vorhersagemodellen zeigte sich auch hinsichtlich der angestrebten Regelziele in Summe ein besseres Ergebnis mit der Verteilungsvorhersage.

Das vorgestellte Framework zur Erzeugung stochastischer Vorhersagen eröffnet zahlreiche weitere Handlungsfelder. So könnte beispielsweise die Erweiterung der Fahrer- und Umfeldmodellierung um zusätzliche Informationen über andere Verkehrsteilnehmer oder Ampeln und Haltestellen zu einer vollständigeren Modellierung der Transferfunktion und potentiell besseren Vorhersagen beitragen. Die Modellierung wurde im Rahmen dieser Untersuchung auf die wichtigsten Einflüsse begrenzt, um eine Behandlung der vollständigen Methodenkette von der Fahrermodellierung über die Parameterschätzung und Vorhersage bis zur vorausschauenden Steuerung zu ermöglichen. Bei entsprechender Verfügbarkeit von umfangreichen Messdaten mit unterschiedlichen Fahrern und Strecken könnten tiefer gehende Untersuchungen bezüglich der unterschiedlichen Modellierungsaspekte erfolgen.

Die prinzipielle Eignung und Umsetzbarkeit vorausschauender Regelansätze in Kombination mit stochastischen Vorhersagen für verbesserte und neue Funktionalitäten für Fahrzeugsysteme konnte in dieser Arbeit nachgewiesen werden. Die stochastische Formulierung hat für beide betrachtete Systeme, trotz der völlig unterschiedlichen Systemeigenschaften, zu einem verbesserten Regelverhalten gegenüber einer Formulierung ohne die Unsicherheiten geführt. Zahlreiche weitere Anwendungsmöglichkeiten sind somit denkbar und die

erarbeitete Methode eröffnet Raum für weiterführende Untersuchungen, an den vorgestellten oder anderen Anwendungsbeispielen.

A Anhang

A.1 Messfahrten

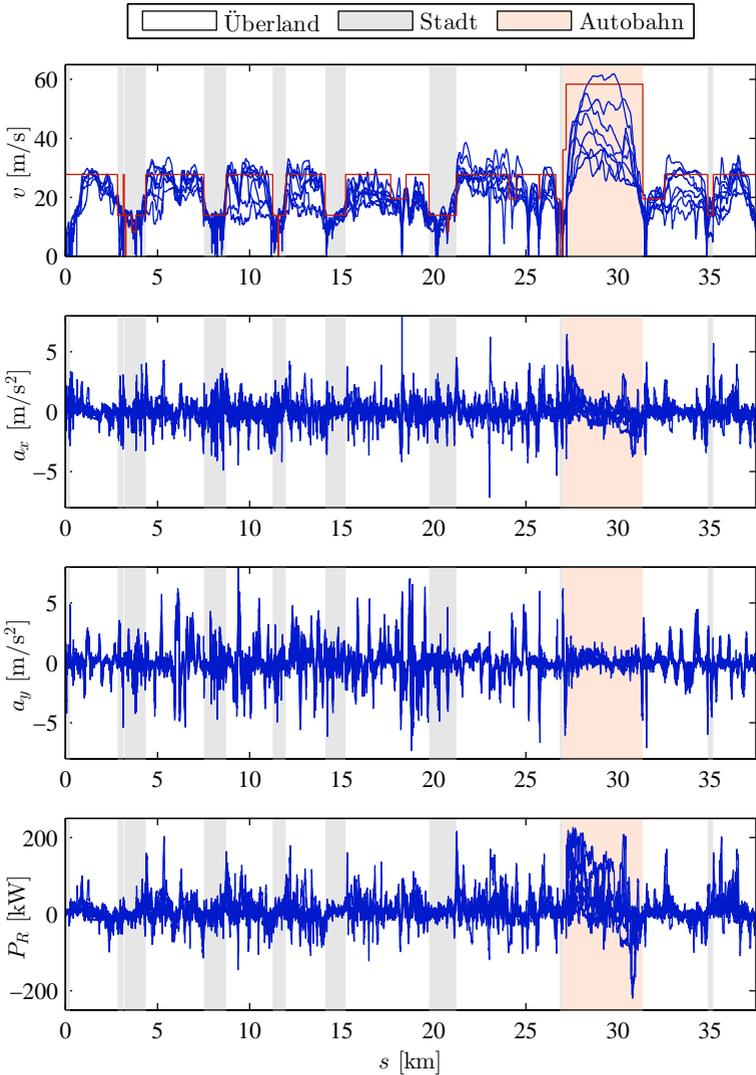


Abb. A.1: Geschwindigkeit v , Längsbeschleunigung a_x , Querbeschleunigung a_y und Radleistung P_R über der Strecke s für alle aufgezeichneten Testfahrten.

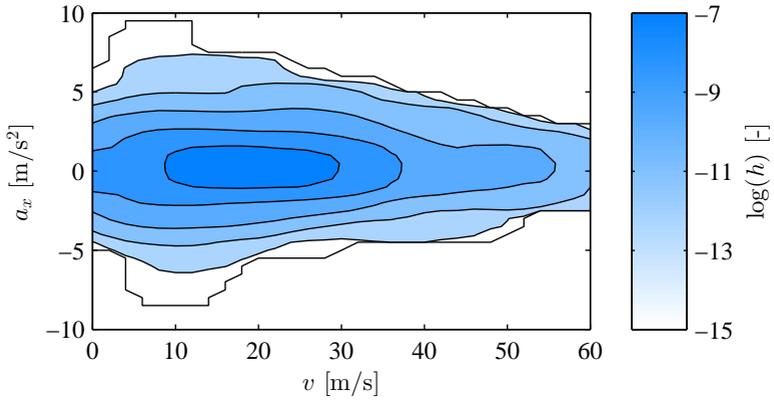


Abb. A.2: Relative Häufigkeitsverteilung h der Kombinationen aus Längsbeschleunigung a_x und Fahrgeschwindigkeit v über alle Fahrten.

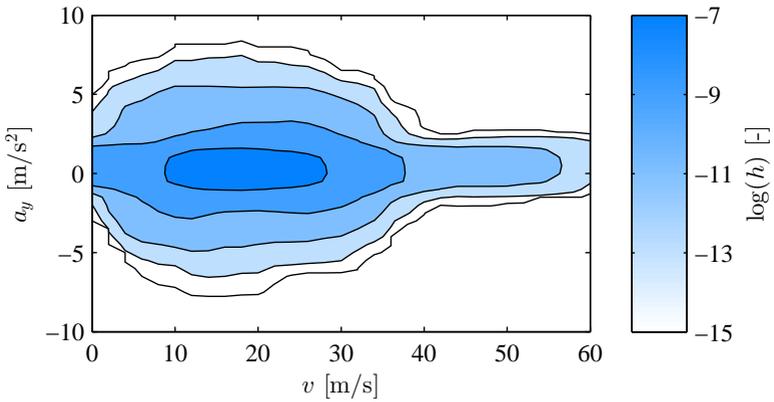


Abb. A.3: Relative Häufigkeitsverteilung h der Kombinationen aus Querbeschleunigung a_y und Fahrgeschwindigkeit v über alle Fahrten.

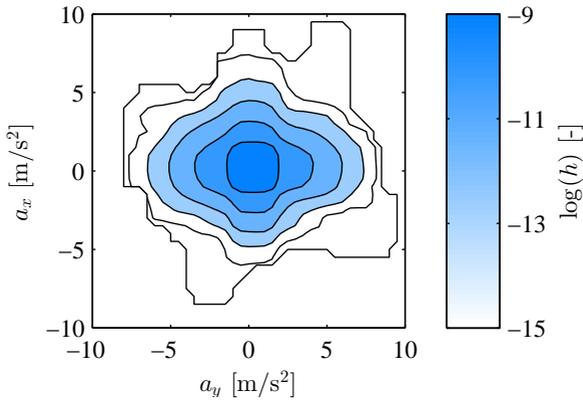


Abb. A.4: Relative Häufigkeitsverteilung h der Kombinationen aus Querbewegung a_y und Längsbewegung a_x über alle Fahrten.

A.2 Zeitdiskrete Auswertung der Fahrzeugbewegungsgleichung

Die zeitdiskrete Berechnung der Fahrzeugbewegung erfolgt mit einem Zeitschritt $\Delta t = 1$ s. Dabei wird von einem stückweise konstanten Ruck ausgegangen. Für eine Zielbeschleunigung $a_{x,t}$ kann mit

$$j_t = \frac{a_{x,t} - a_{x,t-1}}{\Delta t} \quad (\text{A.1})$$

der notwendige Ruck zur Erreichung der Zielbeschleunigung innerhalb von einer Sekunde ermittelt werden. Für die Geschwindigkeit v_t gilt dann

$$\begin{aligned} v_t &= v_{t-1} + a_{x,t-1}\Delta t + \frac{1}{2}j_t\Delta t^2 \\ &= v_{t-1} + \frac{1}{2}(a_{x,t-1} + a_{x,t})\Delta t. \end{aligned} \quad (\text{A.2})$$

Die neue Fahrzeugposition berechnet sich entsprechend zu

$$\begin{aligned} s_t &= s_{t-1} + v_{t-1}\Delta t + a_{x,t-1}\Delta t^2 + \frac{1}{6}j_t\Delta t^3 \\ &= s_{t-1} + v_{t-1}\Delta t + \left(\frac{a_{x,t-1}}{3} + \frac{a_{x,t}}{6}\right)\Delta t^2. \end{aligned} \quad (\text{A.3})$$

Die Querbeschleunigung ermittelt sich aus der Straßenkrümmung $\kappa(s_t)$ an der Fahrzeugposition und der Geschwindigkeit mit

$$a_{y,t} = v_t^2 \cdot \kappa(s_t). \quad (\text{A.4})$$

Die Radleistung ergibt sich aus dem Fahrwiderstandsmodell und wird durch

$$P_{R,t} = F_{W,t}(\cdot) \cdot v_t \quad (\text{A.5})$$

berechnet.

A.3 Stationäre Verteilung und mittlere Zustandsaufenthaltszeiten einer Markov-Kette

Stationäre Verteilung: Eine charakteristische Eigenschaft einer Markov-Kette bzw. ihrer Übergangsmatrix M ist die stationäre Verteilung. Die stationäre Verteilung π_∞ ist dadurch charakterisiert, dass sich die Zustandsverteilung ausgehend von der stationären Verteilung im Zeitverlauf nicht ändert. Für die stationäre Verteilung gilt somit die Bedingung

$$\pi_\infty^T \cdot M = \pi_\infty^T. \quad (\text{A.6})$$

Diese stationäre Verteilung (sofern existent) ist von besonderem Interesse, da sie auch den Erwartungswert für die Zeitanteile beschreibt, zu denen sich die Markov-Kette in den jeweiligen Zuständen aufhält. Die stationäre Verteilung kann über das Lösen eines linearen Gleichungssystems bestimmt werden (vgl. (CWKH⁺ 13)).

Zustandsaufenthaltszeiten: Die Wahrscheinlichkeit, dass die Markov-Kette einen Zustand i nach einem Zeitschritt verlässt beträgt

$$p_{i,1} = (1 - p_{ii}), \quad (\text{A.7})$$

mit der Zustandsübergangswahrscheinlichkeit $p_{ii} = P(S_t = i | S_{t-1} = i)$. Die Wahrscheinlichkeit, dass die Markov-Kette den Zustand i nach n Zeitschritten verlässt, im Folgenden $p_{i,n}$ bezeichnet, beträgt dann entsprechend

$$p_{i,n} = p_{ii}^{(n-1)} (1 - p_{ii}). \quad (\text{A.8})$$

Die mittlere Aufenthaltsdauer in Zeitschritten für den Zustand i ergibt sich dann mit

$$\begin{aligned} \bar{n}_i &= \sum_{n=1}^{\infty} n \cdot p_{i,n} \\ \bar{n}_i &= \sum_{n=1}^{\infty} n \cdot p_{ii}^{(n-1)} \cdot (1 - p_{ii}) \\ \bar{n}_i &= \frac{p_{ii}}{(1 - p_{ii})} + 1. \end{aligned} \quad (\text{A.9})$$

A.4 Rekursive Schätzung von Mittelwert und Varianz

Im Folgenden wird die rekursive Schätzung von Mittelwert und Varianz einer Zeitreihe entsprechend der Verfahrensweise von (Wel62) beschrieben. Der arithmetische Mittelwert von n Beobachtungen der Zeitreihe \underline{x} berechnet sich zu

$$\bar{x}_n = \frac{1}{n} \sum_{t=1}^n x_t \quad (\text{A.10})$$

und ist gleichzeitig der Schätzwert für den Erwartungswert μ der Verteilung X , falls $x_t \propto X$.

Diese Berechnungsvorschrift kann durch

$$\hat{\mu}_n = \bar{x}_n = \frac{1}{n} \sum_{t=1}^n x_t = \frac{1}{n} \left(x_n + \sum_{t=1}^{n-1} x_t \right) = \frac{1}{n} x_n + \frac{n-1}{n} \bar{x}_{n-1} \quad (\text{A.11})$$

in eine rekursive Form gebracht werden.

Die Varianz σ^2 der Verteilung wird über die korrigierte Stichprobenvarianz s_n^2 geschätzt:

$$\hat{\sigma}_n^2 = s_n^2 = \frac{1}{n-1} \sum_{t=1}^n (x_t - \bar{x}_n)^2. \quad (\text{A.12})$$

Auch hier ist eine Umformung in eine rekursive Berechnungsvorschrift möglich:

$$\begin{aligned} s_n^2 &= \frac{1}{n-1} \sum_{t=1}^n (x_t - \bar{x}_n)^2 \\ &= \frac{1}{n-1} \sum_{t=1}^{n-1} \left[(x_t - \bar{x}_{n-1}) - \frac{1}{n} (x_n - \bar{x}_{n-1}) \right]^2 \\ &\quad + \frac{n-1}{n^2} (x_n - \bar{x}_{n-1})^2 \\ &= \frac{1}{n-1} \sum_{t=1}^{n-1} (x_t - \bar{x}_{n-1})^2 + \left[\frac{1}{n^2} + \frac{(n-1)}{n^2} \right] (x_n - \bar{x}_{n-1})^2 \\ &= \frac{n-2}{n-1} s_{n-1}^2 + \frac{1}{n} (x_n - \bar{x}_{n-1})^2. \end{aligned} \quad (\text{A.13})$$

Diese rekursiven Berechnungsvorschriften sind exakt und numerisch stabil (CGL83).

A.5 Rekursive Schätzung von Parametern eines AR(1)-Modells

Gegeben ist der AR(1)-Prozess

$$x_t = \phi x_{t-1} + \varepsilon_t, \quad \varepsilon_t \propto \mathcal{N}(0, \sigma_\varepsilon^2). \quad (\text{A.14})$$

Die Berechnung der echten Maximum-Likelihood-Schätzwerte für ϕ und σ_ε^2 kann nicht analytisch erfolgen und muss durch iterative numerische Prozeduren ermittelt werden (SS11). Sie eignen sich daher nicht für eine Online-Implementierung. Stattdessen können aber die ML-Schätzwerte bedingt auf die erste Beobachtung, auch CML-Schätzwerte genannt, verwendet werden. Der CML-Schätzwert für ϕ berechnet sich nach (SS11) mit

$$\hat{\phi}_n^{CML} = \frac{\sum_{t=2}^n (x_t - \bar{x})(x_{t-1} - \bar{x})}{\sum_{t=2}^n (x_{t-1} - \bar{x})^2}. \quad (\text{A.15})$$

Zunächst folgt:

$$\begin{aligned} \hat{\phi}_n^{CML} &= \frac{\sum_{t=2}^n (x_t - \bar{x}_n)(x_{t-1} - \bar{x}_n)}{\sum_{t=2}^n (x_{t-1} - \bar{x})^2} = \frac{\sum_{t=2}^n (x_t x_{t-1} - \bar{x}_n x_t - \bar{x}_n x_{t-1} + \bar{x}_n^2)}{(n-2)s_{n-1}^2} \\ &= \frac{\left(\sum_{t=2}^n x_t x_{t-1} \right) - \bar{x}_n (n\bar{x}_n - x_1) - \bar{x}_n (n-1)\bar{x}_{n-1} + (n-1)\bar{x}_n^2}{(n-2)s_{n-1}^2} \quad (\text{A.16}) \\ &= \frac{\frac{1}{n-1} \left(\sum_{t=2}^n x_t x_{t-1} \right) - \frac{n}{n-1} \bar{x}_n^2 + \frac{1}{n-1} \bar{x}_n x_1 - \bar{x}_n \bar{x}_{n-1} + \bar{x}_n^2}{\frac{n-2}{n-1} s_{n-1}^2}. \end{aligned}$$

Sei weiter

$$\dot{\bar{x}}_n = \frac{1}{n-1} \sum_{t=2}^n x_t x_{t-1}, \quad n > 2, \quad (\text{A.17})$$

mit folgender rekursiven Berechnungsvorschrift:

$$\begin{aligned} \bar{x}_n^{\circ} &= \frac{1}{n-1} \sum_{t=2}^n x_t x_{t-1} \\ &= \frac{1}{n-1} \left(\sum_{t=2}^{n-1} x_t x_{t-1} \right) + \frac{1}{n-1} x_n x_{n-1} \quad (\text{A.18}) \\ &= \frac{n-2}{n-1} \bar{x}_{n-1}^{\circ} + \frac{1}{n-1} x_n x_{n-1}. \end{aligned}$$

Durch einsetzen von Gl. (A.18) in Gl. (A.16) ergibt sich folgende Berechnungsvorschrift für $\hat{\phi}_n^{CML}$:

$$\hat{\phi}_n^{CML} = \frac{\overline{x_n^2} - \frac{n}{n-1}\bar{x}_n^2 + \frac{1}{n-1}\bar{x}_n x_1 - \bar{x}_n \bar{x}_{n-1} + \bar{x}_n^2}{\frac{n-2}{n-1}s_{n-1}^2}. \quad (\text{A.19})$$

Da Gl. (A.19) nur rekursiv berechenbare Größen enthält, ist dies somit eine rekursive Berechnungsvorschrift für $\hat{\phi}_n^{CML}$. Der CML-Schätzwert der Varianz σ_ε ist nach (SS11) durch

$$\begin{aligned} \hat{\sigma}_\varepsilon^{2\ CML} &= \frac{1}{n-1} \sum_{t=2}^n [(x_t - \bar{x}_n) - \phi(x_{t-1} - \bar{x}_n)]^2 \\ &= \frac{1}{n-1} \sum_{t=2}^n [x_t - (1-\phi)\bar{x}_n - \phi x_{t-1}]^2 \\ &= \frac{1}{n-1} \sum_{t=2}^n [x_t^2 + (1-\phi)^2 \bar{x}_n^2 + \phi^2 x_{t-1}^2 \\ &\quad - 2(1-\phi)\bar{x}_n x_t + 2(\phi - \phi^2)\bar{x}_n x_{t-1} \\ &\quad - 2\phi x_t x_{t-1}] \end{aligned} \quad (\text{A.20})$$

gegeben. Die Berechnung der mittleren Summe der Quadrate ab der zweiten Beobachtung erfolgt mit:

$$\begin{aligned} \overline{x_n^2} &= \frac{1}{n-1} \sum_{t=2}^n x_t^2 = \frac{1}{n-1} x_n^2 + \frac{1}{n-1} \sum_{t=2}^{n-1} x_t^2 \\ &= \frac{1}{n-1} x_n^2 + \frac{n-2}{n-1} \overline{x_{n-1}^2}. \end{aligned} \quad (\text{A.21})$$

Damit folgt für Gl. (A.20) weiter

$$\begin{aligned} \hat{\sigma}_\varepsilon^{2\ CML} &= \overline{x_n^2} + (1-\phi)^2 \bar{x}_n^2 + \phi^2 (\overline{x_{n-1}^2} + x_1^2) \\ &\quad - \frac{n}{n-1} 2(1-\phi)\bar{x}_n (\bar{x}_n - \frac{x_1}{n}) \\ &\quad + 2(\phi - \phi^2)\bar{x}_n \bar{x}_{n-1} - 2\phi \overline{x_n^2}. \end{aligned} \quad (\text{A.22})$$

Mit Gl. (A.22) kann somit die rekursive Berechnung des Schätzwertes erfolgen.

A.6 Autokorrelation und -kovarianz eines gefilterten AR(1)-Modells

Sei x_t eine Realisierung eines AR(1)-Prozesses der Form

$$x_t = \phi x_{t-1} + \varepsilon_t, \varepsilon_t \sim \mathcal{N}(0, \sigma_\varepsilon^2). \quad (\text{A.23})$$

Sei weiterhin $x_{T,t}$ die durch ein PT_1 -Glied gefilterte Zeitreihe mit der Differentialgleichung

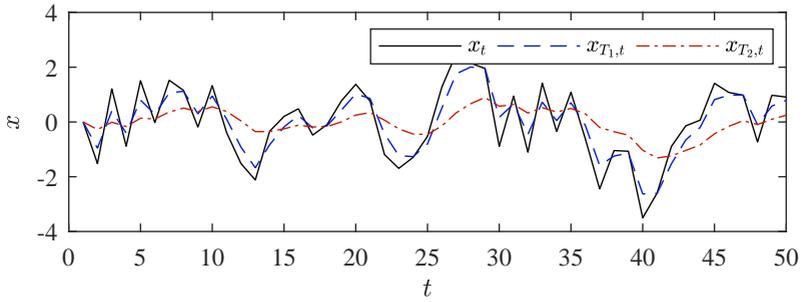
$$T\dot{x}_T + x_T = x. \quad (\text{A.24})$$

Gegeben sind drei beispielhafte Realisierungen des AR(1)-Prozesses für $\sigma_\varepsilon = 1$ mit $\phi \in \{0.5, 0.7, 0.9\}$. Gegeben sind weiterhin die gefilterten Zeitreihen \underline{x}_{T_1} und \underline{x}_{T_2} mit $T = T_1 = 1$ für \underline{x}_{T_1} und $T = T_2 = 5$ für \underline{x}_{T_2} . Abb. A.5 zeigt einen Ausschnitt der ungefilterten und gefilterten Zeitreihen. In Tabelle A.1 sind die Stichprobenautokorrelation r_1 und die Stichprobenautokovarianz γ_1 nach 1000 Zeitschritten aufgeführt. Deutlich zu erkennen ist die Zunahme

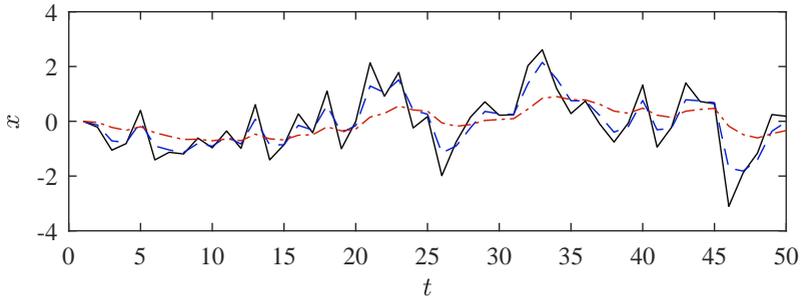
Tabelle A.1: Stichprobenautokorrelation r_1 und -autokovarianz γ_1 für AR(1)-Zeitreihen x_t und deren PT_1 -gefilterte äquivalente $x_{T_1,t}$ und $x_{T_2,t}$ mit $\phi = 0.5$, $\phi = 0.7$ und $\phi = 0.9$ sowie $T_1 = 1$ und $T_2 = 5$.

	x_t	$x_{T_1,t}$	$x_{T_2,t}$
$r_1(\cdot)$			
$\phi = 0.5$	0.509	0.737	0.937
$\phi = 0.7$	0.682	0.837	0.961
$\phi = 0.9$	0.879	0.942	0.985
$\gamma_1(\cdot)$			
$\phi = 0.5$	0.708	0.688	0.314
$\phi = 0.7$	1.171	1.103	0.562
$\phi = 0.9$	3.620	3.504	2.411

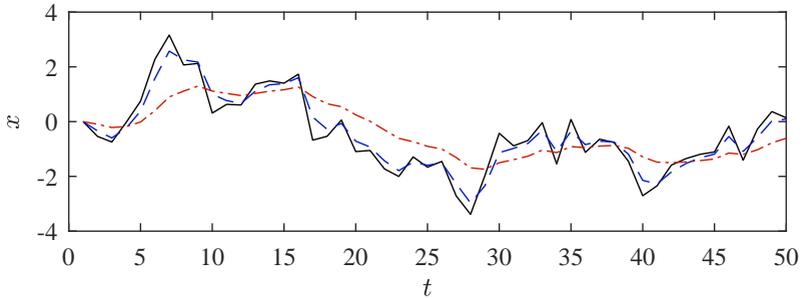
der Autokorrelation sowie Abnahme der Autokovarianz der Zeitreihen mit wachsender Zeitkonstante T .



(a)



(b)



(c)

Abb. A.5: Autoregressiver Prozess x_t sowie die durch ein PT_1 -Glied gefilterten Zeitreihen $x_{T_1,t}$ und $x_{T_2,t}$ für $\phi = 0.5$ (a), $\phi = 0.7$ (b) und $\phi = 0.9$ (c).

A.7 Verifizierung der Parameterschätzung zur Fahrerwunschkynamik

Folgend sind die zur Erzeugung der Testdaten verwendeten Übergangswahrscheinlichkeiten M sowie die zugehörigen stationären Zustandswahrscheinlichkeiten π_∞ aufgeführt.

Ruhiger Fahrer:

$$M_1 = \begin{bmatrix} 0.95 & 0.0125 & 0.0125 & 0.0125 & 0.0125 \\ 0.0375 & 0.85 & 0.0375 & 0.0375 & 0.0375 \\ 0.0625 & 0.0625 & 0.75 & 0.0625 & 0.0625 \\ 0.0875 & 0.0875 & 0.0875 & 0.65 & 0.0875 \\ 0.1125 & 0.1125 & 0.1125 & 0.1125 & 0.55 \end{bmatrix} \quad (\text{A.25})$$

$$\pi_{\infty,1} \approx [0.56 \quad 0.19 \quad 0.11 \quad 0.08 \quad 0.06]^T$$

Moderater Fahrer:

$$M_2 = \begin{bmatrix} 0.75 & 0.0625 & 0.0625 & 0.0625 & 0.0625 \\ 0.0375 & 0.85 & 0.0375 & 0.0375 & 0.0375 \\ 0.0125 & 0.0125 & 0.95 & 0.0125 & 0.0125 \\ 0.0375 & 0.0375 & 0.0375 & 0.85 & 0.0375 \\ 0.0625 & 0.0625 & 0.0625 & 0.0625 & 0.75 \end{bmatrix} \quad (\text{A.26})$$

$$\pi_{\infty,2} \approx [0.10 \quad 0.16 \quad 0.48 \quad 0.16 \quad 0.10]^T$$

Sportlicher Fahrer:

$$M_3 = \begin{bmatrix} 0.55 & 0.1125 & 0.1125 & 0.1125 & 0.1125 \\ 0.0875 & 0.65 & 0.0875 & 0.0875 & 0.0875 \\ 0.0625 & 0.0625 & 0.75 & 0.0625 & 0.0625 \\ 0.0375 & 0.0375 & 0.0375 & 0.85 & 0.0375 \\ 0.0125 & 0.0125 & 0.0125 & 0.0125 & 0.95 \end{bmatrix} \quad (\text{A.27})$$
$$\pi_{\infty,3} \approx [0.06 \quad 0.08 \quad 0.11 \quad 0.19 \quad 0.56]^T$$

Abb. A.6, A.7 und A.8 zeigen die Zustandswahrscheinlichkeiten π_t zu den erzeugten Testdaten, ermittelt nach 5 Iterationen des Baum-Welch-Algorithmus und mittels des rekursiven Verfahrens (Online-EM) nach (Cap11). In den Abbildungen A.9, A.10 und A.11 sind die zugehörigen Übergangsmatrizen abgebildet.

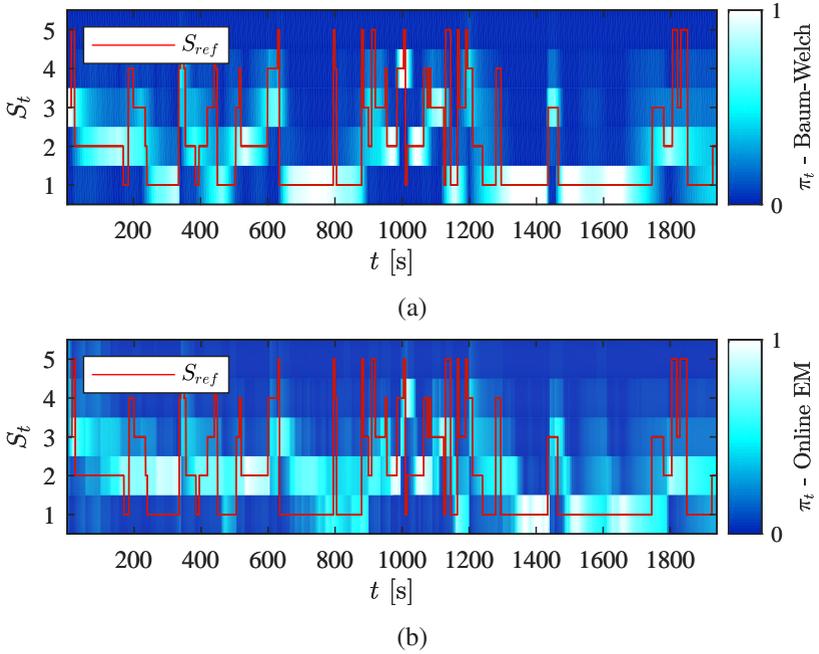
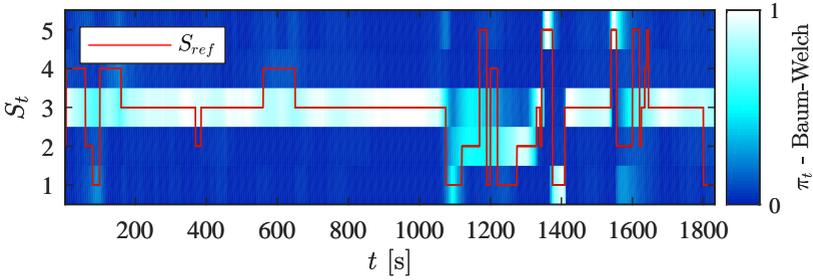
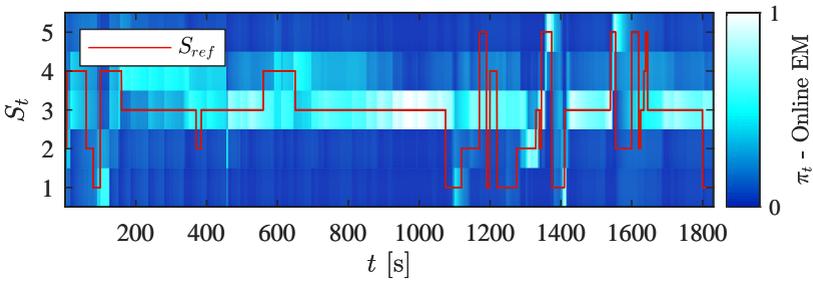


Abb. A.6: Zustandswahrscheinlichkeiten π_t für Testdaten erzeugt mit Beispiel-Zustandsübergangsmatrix M_1 . Ermittelt mit einer Schätzung der Zustandsübergangsmatrix \hat{M} nach fünf Iterationen des Baum-Welch-Algorithmus (a) und rekursiv mit Online EM (b).



(a)



(b)

Abb. A.7: Zustandswahrscheinlichkeiten π_t für Testdaten erzeugt mit Beispiel-Zustandsübergangsmatrix M_2 . Ermittelt mit einer Schätzung der Zustandsübergangsmatrix \hat{M} nach fünf Iterationen des Baum-Welch-Algorithmus (a) und rekursiv mit Online EM (b).

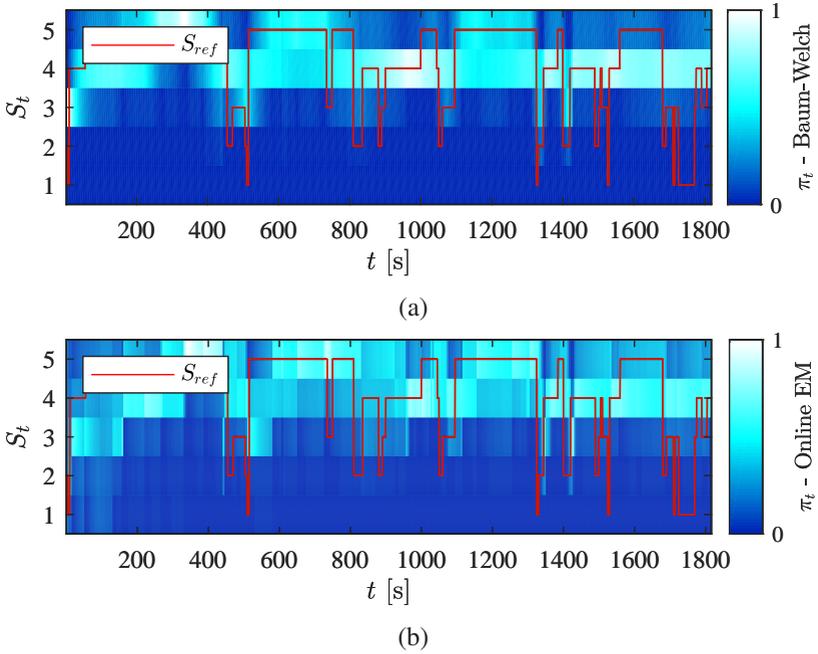


Abb. A.8: Zustandswahrscheinlichkeiten π_t für Testdaten erzeugt mit Beispiel-Zustandsübergangsmatrix M_3 . Ermittelt mit einer Schätzung der Zustandsübergangsmatrix \hat{M} nach fünf Iterationen des Baum-Welch-Algorithmus (a) und rekursiv mit Online EM (b).

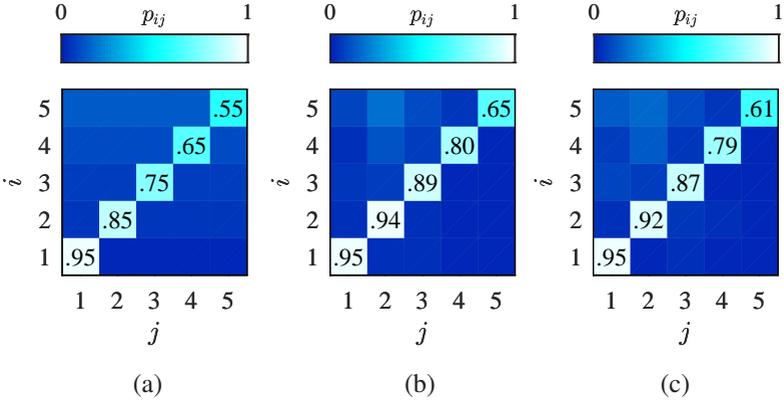


Abb. A.9: Übergangsmatrix M_1 (a) und die Schätzungen \hat{M} nach fünf Iterationen des Baum-Welch-Algorithmus (b) und rekursiv mit Online-EM (c).

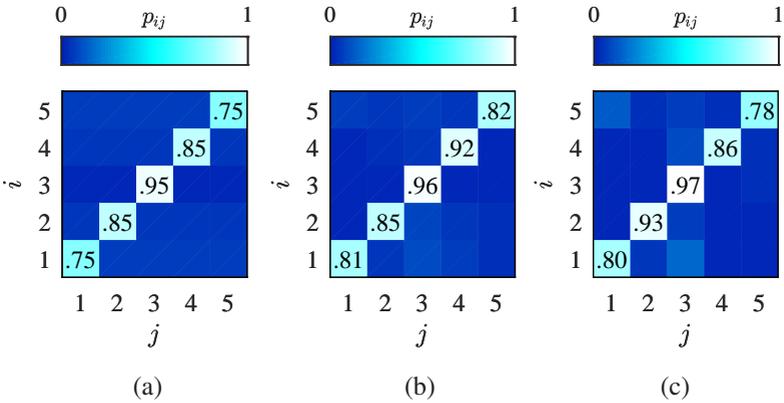


Abb. A.10: Übergangsmatrix M_2 (a) und die Schätzungen \hat{M} nach fünf Iterationen des Baum-Welch-Algorithmus (b) und rekursiv mit Online-EM (c).

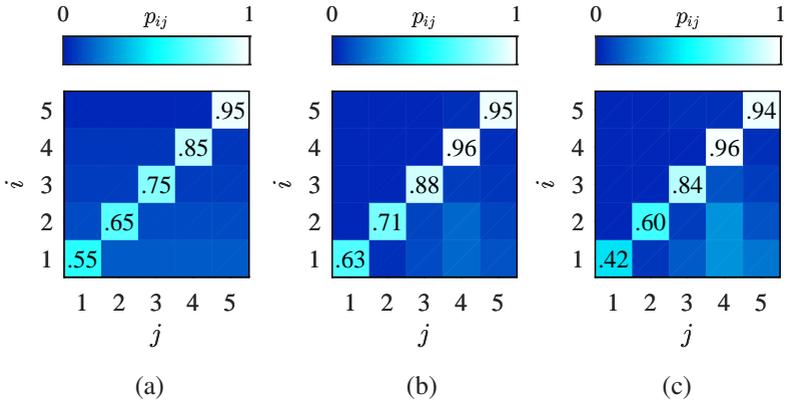


Abb. A.11: Übergangsmatrix M_3 (a) und die Schätzungen \hat{M} nach fünf Iterationen des Baum-Welch-Algorithmus (b) und rekursiv mit Online-EM (c).

A.8 Berechnung der Wasserstein-Distanz W_p zwischen Sample-Verteilungen

Gegeben sind zwei Verteilungen $Y_{K_1} = \{y_k\}_{k \in [1, K_1]}$ und $Y_{K_2} = \{y_k\}_{k \in [1, K_2]}$ mit $y_k \in \mathbb{R}^1$. Gesucht ist die Wasserstein-Distanz W_1 der beiden Verteilungen. Nach Gl. (3.77) gilt

$$W_p(Y_{K_1}, Y_{K_2}) = \left(\int_{-\infty}^{\infty} |F_{Y_{K_1}}(y) - F_{Y_{K_2}}(y)|^p dy \right)^{\frac{1}{p}} \quad (\text{A.28})$$

mit den Verteilungsfunktionen $F_{Y_{K_1}}(y)$ und $F_{Y_{K_2}}(y)$. Die Verteilungsfunktion einer Sample-Verteilungen ist als Treppenfunktionen mit

$$F_{Y_K}(y) = \sum_{k=1}^K p_k \cdot \mathbf{1}_{y_k(i)}(y), \quad (\text{A.29})$$

$$\mathbf{1}_{y_k(i)}(y) = \begin{cases} 1 & \text{falls } y \geq y_k(i) \\ 0 & \text{sonst} \end{cases}$$

gegeben. Sei $O = \{o_k\}_{k \in [1, K_1 + K_2]}$ die geordnete Menge der vereinigten Menge $\{Y_{K_1} \cup Y_{K_2}\}$, sodass $o_k \leq o_l$ für $k < l$. Da die Verteilungsfunktionen stückweise konstant sind, kann die Wasserstein-Distanz zwischen Y_{K_1} und Y_{K_2} dann mit

$$W_p(Y_{K_1}, Y_{K_2}) = \left(\sum_{k=1}^{K_1 + K_2 - 1} \left| F_{\hat{Y}_{K_1}}(o_k) - F_{\hat{Y}_{K_2}}(o_k) \right|^p \cdot (o_{k+1} - o_k) \right)^{\frac{1}{p}} \quad (\text{A.30})$$

berechnet werden.

A.9 Abbildungen zur Konvergenz der Monte-Carlo-Approximation

Abbildungen zur Konvergenzuntersuchung der Monte-Carlo-Approximation, ergänzend zu Abschnitt 3.7.2.

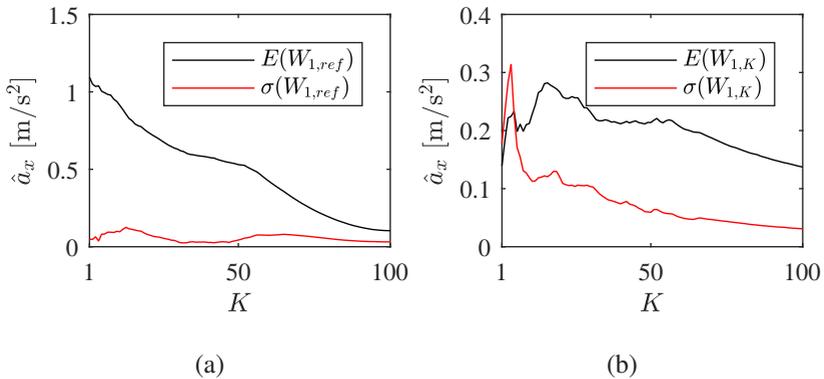


Abb. A.12: Bewertung der Vorhersage der Längsbeschleunigung \hat{a}_x abhängig von der Anzahl an Samples K . (a) Konvergenz: Mittelwert und Standardabweichung der Wasserstein-Distanz von 10 Vorhersagen mit K Samples zur Referenzvorhersage mit 500 Samples. (b) Diskrepanz: Mittelwert und Standardabweichung der Wasserstein-Distanz zwischen 10 Vorhersagen mit K Samples.

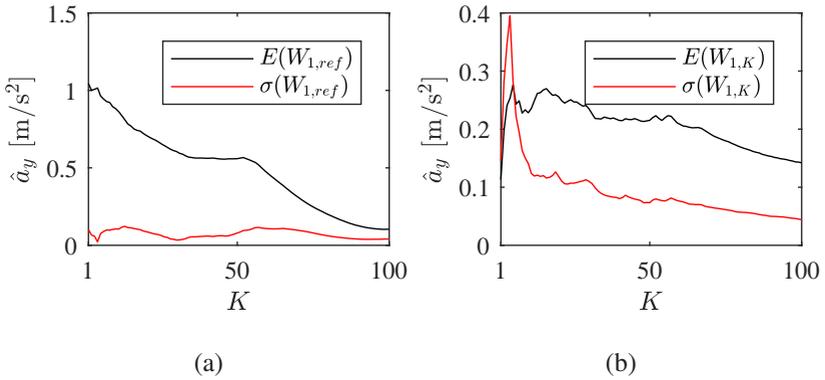


Abb. A.13: Bewertung der Vorhersage der Querbeschleunigung \hat{a}_y abhängig von der Anzahl an Samples K . (a) Konvergenz: Mittelwert und Standardabweichung der Wasserstein-Distanz von 10 Vorhersagen mit K Samples zur Referenzvorhersage mit 500 Samples. (b) Diskrepanz: Mittelwert und Standardabweichung der Wasserstein-Distanz zwischen 10 Vorhersagen mit K Samples.

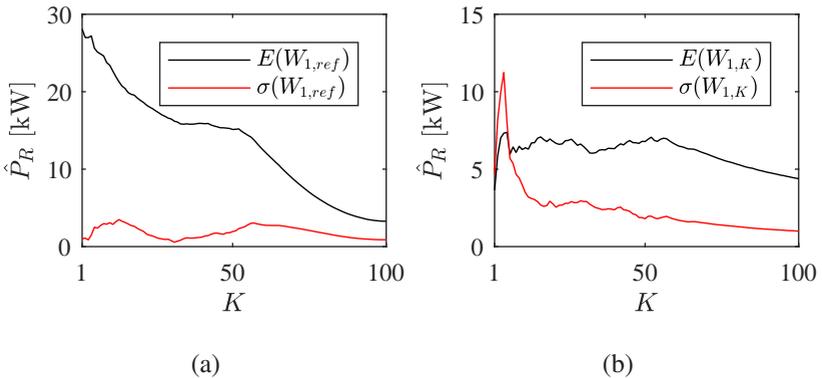


Abb. A.14: Bewertung der Vorhersage \hat{P}_R der Geschwindigkeit abhängig von der Anzahl an Samples K . (a) Konvergenz: Mittelwert und Standardabweichung der Wasserstein-Distanz von 10 Vorhersagen mit K Samples zur Referenzvorhersage mit 500 Samples. (b) Diskrepanz: Mittelwert und Standardabweichung der Wasserstein-Distanz zwischen 10 Vorhersagen mit K Samples.

A.10 Abbildungen zu Abschnitt 3.8.4

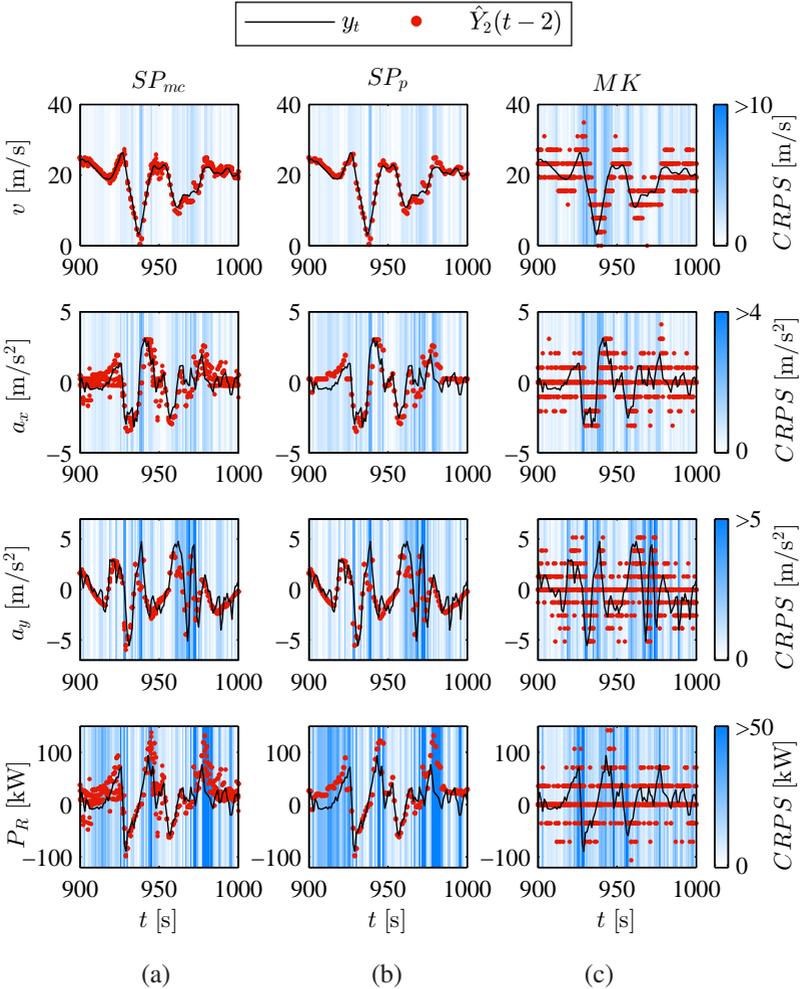


Abb. A.15: Realer Verlauf y_t und die zwei Sekunden Vorhersage $\hat{Y}_2(t-2)$ für den Zeitpunkt t für das stochastische Modell (a), die Punktvorhersage (b) und die Markov-Kette (c). Die Hintergrundfarbe indiziert die Vorhersagegüte $crps$ für diesen Zeitpunkt.

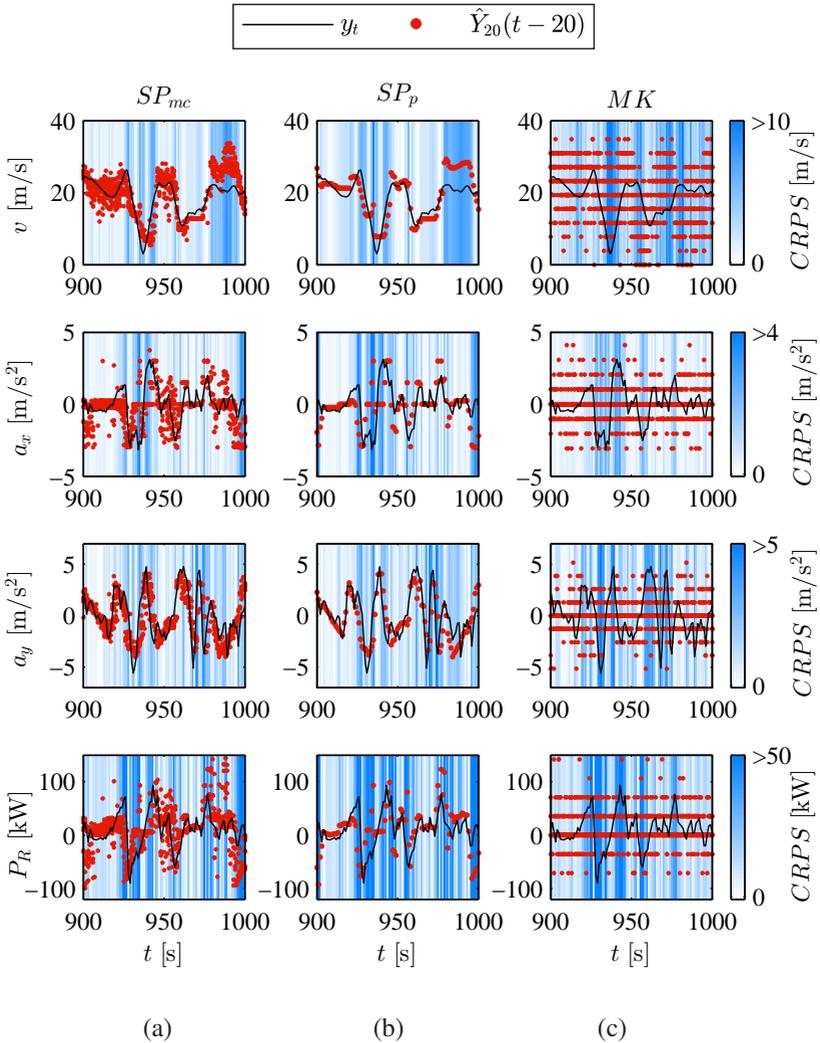


Abb. A.16: Realer Verlauf y_t (Geschwindigkeit v , Längsbeschleunigung a_x , Querbeschleunigung a_y und Radleistung P_R) und die 20 Sekunden Vorhersage $\hat{Y}_{20}(t-20)$ für den Zeitpunkt t für das stochastische Modell (a), die Punktvorhersage (b) und die Markov-Kette (c). Die Hintergrundfarbe indiziert die Vorhersagegüte $crps$ für diesen Zeitpunkt.

Nomenklatur

Abkürzungen

Abkürzung	Bedeutung
ADAS	Advanced Driver Assistance Systems
AR	Autoregressiver Prozess
ARIMA	Autoregressive Integrated Moving Average Prozess
ASM	Asynchronmaschine
CAN	Controller Area Network
CML	Conditional-Maximum-Likelihood
CRPS	Continous Ranked Probability Score
DP	Dynamische Programmierung
E-Fahrzeug	elektrisch angetriebenes Fahrzeug
EH	Elektronischer Horizont
EM	Expectation-Maximization-Methode
ES	Energy Score
MES	Mean Energy Score
ML	Maximum-Likelihood
GDP	Gross Domestic Product (Bruttoinlandsprodukt)
GPS	Global Positioning System
GMM	Gaussian Mixture Model (Gauß'sche Mischverteilung)

HMM	Hidden Markov Model
HUCS	Heuristic-Uniform-Cost-Search
MA	Moving Average Prozess
MAE	Mean Average Error
MAPE	Mean Average Percentage Error
MCRPS	Mean Continuous Ranked Probability Score
MPC	Model Predictive Control (Modellprädiktive Regelung)
MPP	Most Probable Path (wahrscheinlichster Pfad)
MSE	Mean Square Error (mittlerer quadratischer Fehler)
SMPC	Stochastic Model Predictive Control
PSD	Prädiktive Streckendaten
PSM	Permanenterregte Synchronmaschine
PWARX	Piecewise Affine Autoregressive Models with Exogenous Input
RMES	Root Mean Energy Score (Wurzel des mittleren Energy Score)
RMSE	Root Mean Square Error (Wurzel des mittleren quadratischen Fehlers)
TLC	Time to Line Crossing
UCS	Uniform-Cost-Search

Formelzeichen

Zeichen	Einheit	Bedeutung
a_x	$\frac{\text{m}}{\text{s}^2}$	Längsbeschleunigung
a_y	$\frac{\text{m}}{\text{s}^2}$	Querbeschleunigung
\tilde{a}_y	$\frac{\text{m}}{\text{s}^2}$	modifizierte Querbeschleunigung
c_p	-	spezifische Wärmekapazität
c_W	-	Luftwiderstandsbeiwert
$c_{t,\Gamma}$	-	Zeitschrittfaktor stochastischer Prozess Γ
e	divers	Prädiktorvariable
f_s	-	Systemübertragungsfunktion
f_R	-	Rollwiderstandsbeiwert
f_T	-	Transferfunktion des Vorhersagemodells
g	$\frac{\text{m}}{\text{s}^2}$	Gravitationskonstante
j	$\frac{\text{m}}{\text{s}^3}$	Ruck
l	mm	Länge
m	kg	Fahrzeugmasse
m'	kg	Fahrzeugmasse mit Berücksichtigung der rotatorischen Masseanteile
n	-	Anzahl Messzeitpunkte
n_{max}	-	Beschränkung der Messzeitpunkte für rekursive Lernverfahren (Lernhorizont)
p	-	Wahrscheinlichkeit
\dot{q}	$\frac{\text{kW}}{\text{K}}$	spezifische Wärmeleistung
r	m	Bahnradius
s	m	Weg, Position

$s_{(\cdot)}$	-	Segment mit Index (\cdot)
s_{ID}	-	Zielsegment
t	-	Zeitindex mit Diskretisierung Δt
\bar{t}	-	Zeitindex bezogen auf aktuellen Zeitpunkt
t'	-	Zeitindex mit Diskretisierung $c_{t,\Gamma} \cdot \Delta t$
t_{lh}	s, min	Lernhorizont (zeitlich)
u	divers	Steuergröße
v	$\frac{m}{s}, \frac{km}{h}$	Geschwindigkeit
v_{lim}	$\frac{m}{s}, \frac{km}{h}$	Geschwindigkeitslimit
v_{max}	$\frac{m}{s}, \frac{km}{h}$	Freifahrtgeschwindigkeit (unbeschränkte Strecke)
v_Z	$\frac{m}{s}$,	Zielgeschwindigkeit
v_{Δ}	$\frac{m}{s}$,	Geschwindigkeitsoffset
x	divers	Systemzustand oder allgemeine Variable
y	divers	Vorhersagegröße bzw. Umgebungszustand
z	divers	Störgröße
Δ_t	s	Zeitdiskretisierung
<hr/>		
α	-	Steigungswinkel (Kapitel 3)
α	$\frac{W}{m^2K}$	Wärmeübergangskoeffizient (Abschnitt 4.3)
ε	divers	Rauschterm (AR-Prozess)
η	-	Wirkungsgrad
μ	divers	Mittelwert
λ	-	Rekursionsgewichtungparameter
ϕ	-	Autoregressionsparameter
π	-	Zustandswahrscheinlichkeitsverteilung (HMM)
π_{∞}	-	Stationäre Zustandsverteilung (HMM)
π	-	Regelstrategie (Optimalsteuerung bzw. MPC)
ρ_L	$\frac{kg}{m^3}$	Luftdichte

σ	divers	Standardabweichung
γ	divers	Parameter der Transferfunktion f_T
κ	$\frac{1}{\text{m}}$	Bahnkrümmung
ϑ	divers	Beobachtungsgröße zur Ermittlung der Parameter θ (Kapitel 3)
ϑ	$^{\circ}\text{C}$	Temperatur (Abschnitt 4.3)
θ	divers	Prozessparameter von Γ
Θ	-	Parameter eines HMM
Γ	-	Stochastische Prozessbeschreibung für γ

A	mm^2, m^2	Fläche
B_p	divers	Breite des zentralen p -Vorhersageintervalls
C	$\frac{\text{J}}{\text{K}}$	Wärmekapazität
D	mm	Durchmesser
F_B	N	Beschleunigungswiderstand
F_L	N	Luftwiderstand
F_S	N	Steigungswiderstand
F_R	N	Rollwiderstands
F_W	N	Fahrwiderstand
J	-	Güte-/Kostenfunktion
K	-	Samplegröße
M	-	Zustandsübergangsmatrix (Markov-Kette bzw. HMM)
MK		Monte-Carlo-Vorhersage einer Markov-Kette
N_m	-	Diskretisierungsparameter für HUCS
N_{HMM}	-	Anzahl Zustände Hidden-Markov-Model
O	divers	Beobachtungsgröße Hidden-Markov-Model
P	W, kW	Leistung
P_R	kW	Radleistung

\dot{Q}	W, kW	Wärmestrom
R	-	Regelgüte
S	-	Zustandsraum einer Markov-Kette bzw. eines HMM
S_{MPP}	-	Menge aller Segmente des Most Probable Path
T	-	Horizont (Schritte) der Vorhersage bzw. des Optimalsteuerungsproblems
\mathcal{T}_{PSD}	-	Segmentbaum des elektronischen Horizonts
S_t	-	Zeitabhängiger Zustand einer Markov-Kette bzw. eines HMM
SP_{mc}		Monte-Carlo-Vorhersage des stochastischen Modells
SP_p		Punktvorhersage des stochastischen Modells
\mathcal{U}	divers	Zulässiger Bereich der Steuergrößen
V	-	Zielfunktion
V_Z	$\frac{m}{s}$	Verteilungsfunktion der Zielgeschwindigkeit
V_Z	$\frac{m}{s}$	Verteilungsfunktion der Zielgeschwindigkeit
V_{max}	$\frac{m}{s}$	Verteilungsfunktion der Freifahrtgeschwindigkeit
W_p	divers	Wasserstein-Distanz der Ordnung p
X	divers	Verteilung eines Systemzustands
\mathcal{X}	divers	Zulässiger Zustandsraum
Y	divers	Verteilung einer Vorhersagegröße bzw. des Umgebungszustands

Mathematische Schreibweisen

Notation	Bedeutung
x^T	Transponierte von x
$x(y)$	$\left\{ \begin{array}{l} \text{Wert an der Stelle } y \text{ des Vektors } x, y \in \mathbb{N}^+ \\ \text{Wert der Funktion } x \text{ an der Stelle } y \end{array} \right.$
$x = f(y)$	x ist eine von y abhängige Funktion
$\{x_1, x_2, \dots\}$	Menge
$\{\dots\}_{[n \times m]}$	Kardinalität einer Menge
\underline{x}	Zeitreihe
x_t	Wert einer Zeitreihe \underline{x} zum Zeitpunkt t
$x_{1:T}$	Werte $[x_1, x_2, \dots, x_T]$ der Zeitreihe \underline{x}
x_i	Indizierung
$(\dot{\cdot})$	Zeitableitung
$(\cdot)^*$	Optimaler Wert bzw. optimale Ausprägung von (\cdot)
$(\cdot)_{max}$	Maximalwert
$(\cdot)_{min}$	Minimalwert
$(\bar{\cdot})$	Mittelwert
$(\hat{\cdot})$	Schätzwert oder Vorhersage
$\mathbb{E}(\cdot)$	Erwartungswert
$\sigma(\cdot)$	Standardabweichung
$x \sim X$	x folgt der Verteilung oder dem stochastischen Prozess X
$A \wedge B$	Aussage A und Aussage B
$A \vee B$	Aussage A und/oder B
$\mathcal{N}(\mu, \sigma^2)$	Normalverteilung mit Mittelwert μ und Varianz σ^2

$\mathcal{U}(a, b)$	Gleichverteilung auf dem Intervall $[a, b]$
$\min(\cdot), \min_x(\cdot)$	Minimum von (\cdot) über alle Möglichkeiten für x
$\operatorname{arg\,min}(\cdot)$	Argument welches (\cdot) minimiert
$\mathbf{1}(\cdot)$	Heaviside-Funktion
$\mathbf{1}_a(x)$	Heaviside-Funktion $\mathbf{1}(x - a)$
$\delta(\cdot)$	Dirac-Funktion
$\delta_a(x)$	Dirac-Funktion $\delta(x - a)$
$P(\cdot)$	Wahrscheinlichkeit von (\cdot)
$F(\cdot)$	Verteilungsfunktion
u. d. N.	Unter der Nebenbedingung

Literaturverzeichnis

- [AEJ17] ALTAF, Faisal; EGARDT, Bo; JOHANNESSON MARDH, Lars: Load Management of Modular Battery Using Model Predictive Control: Thermal and State-of-Charge Balancing. In: *IEEE Transactions on Control Systems Technology* 25 (2017), Nr. 1, S. 47–62
- [AG09] 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
- [AGJ03] AP, Ngy-Srun; GUERRERO, Pascal; JOUANNY, Philippe: Influence of Fan System Electric Power on the Heat Performance of Engine Cooling Module. In: *SAE Technical Paper* Bd. 2003-01-0275. Warrendale: SAE International, 2003
- [AMT12] ANGKITITRAKUL, Pongtep; MIYAJIMA, Chiyomi; TAKEDA, Kazuya: Impact of Driving Context on Stochastic Driver-Behavior Model. In: *2012 IEEE International Conference on Vehicular Electronics and Safety (ICVES)*. Istanbul, 2012, S. 163–168
- [Arm01] ARMSTRONG, J. S. (Hrsg.): *Principles of Forecasting: A Handbook for Researchers and Practitioners*. New York and Boston and Dordrecht and London and Moskau: Kluwer Academic Publishers, 2001. – ISBN 0–7923–7930–6
- [ASHI08] AKITA, Toshikazu; SUZUKI, Tatsuya; HAYAKAWA, Soichiro; INAGAKI, Shinkichi: Analysis and synthesis of driving behavior based on mode segmentation. In: *2008 International Conference on Control, Automation and Systems*. Seoul: IEEE, 2008, S. 2884–2889

- [Aue15] AUER, Markus: *Ein Beitrag zur Erhöhung der Reichweite eines batterieelektrischen Fahrzeugs durch prädiktives Thermomanagement*. Stuttgart, Universität Stuttgart, Diss., 2015
- [AWWK15] AUER, Markus; WIEDEMANN, Jochen; WIDDECKE, Nils; KUTHADA, Timo: Reichweitensteigerung durch Thermomanagement am Elektrofahrzeug. In: *ATZ* 117 (2015), Nr. 07, S. 86–93
- [Bac05] BACK, Michael: *Prädiktive Antriebsregelung zum energieoptimalen Betrieb von Hybridfahrzeugen*. Karlsruhe, Universität Karlsruhe, Diss., 2005
- [Bau19] BAUER, Kai-Lukas: *Echtzeit-Strategieplanung für vorausschauendes automatisiertes Fahren*. Karlsruhe, Karlsruher Institut für Technologie, Diss., 2019
- [BD16] BROCKWELL, Peter J.; DAVIS, Richard A.: *Introduction to Time Series and Forecasting*. 3rd Edition. New York and Berlin and Heidelberg and Barcelona: Springer International Publishing, 2016 (Springer Texts in Statistics)
- [Bel57] BELLMAN, Richard: *Dynamic Programming*. Princeton: Princeton University Press, 1957
- [Bel62] BELLMAN, Richard: *Applied Dynamic Programming*. Princeton: Princeton University Press, 1962
- [Bil98] BILMES, Jeff A.; INTERNATIONAL COMPUTER SCIENCE INSTITUTE (Hrsg.): *A Gentle Tutorial of the EM Algorithm and its Application to Parameter Estimation for Gaussian Mixture and Hidden Markov Models*. Berkeley, 1998. (TR-97-021)
- [BJRL15] BOX, George E. P.; JENKINS, Gwilym M.; REINSEL, Gregory C.; LJUNG, Greta M.: *Time Series Analysis: Forecasting and Control*. 5th Edition. Hoboken: John Wiley & Sons, Inc., 2015
- [BLEK10] BRAUN, Mathias; LINDE, Matthias; EDER, Andreas; KOZLOV, Evgeny: Looking forward: Das vorausschauende Wärmemanagement zur Optimierung von Effizienz und Dynamik. In: *dSPACE Magazin* 8 (2010), Nr. 2, S. 14–19

- [BLH17] BALAJI, T.; LAI, M. D.; HARISH, S.: Convective heat transfer coefficient and pressure drop of water-ethylene glycol mixture with graphene nanoplatelets. In: *Experimental Thermal and Fluid Science* 80 (2017), S. 67–76
- [BMF10] BASHASH, Saeid; MOURA, Scott J.; FATHY, Hosam K.: Charge Trajectory Optimization of Plug-in Hybrid Electric Vehicles for Energy Cost Reduction and Battery Health Enhancement. In: *Proceedings of the 2010 American Control Conference*. Baltimore: IEEE, 2010, S. 5824–5831
- [BNKZ11] BÄR, Tobias; NIENHÜSER, Dennis; KOHLHAAS, Ralf; ZÖLLNER, Marius: Probabilistic Driving Style Determination by means of a Situation Based Analyses of the Vehicle Data. In: *2011 14th International IEEE Conference on Intelligent Transportation Systems*. Washington: IEEE, 2011, S. 1698–1703
- [BPSW70] BAUM, Leonard E.; PETRIE, Ted; SOULES, George; WEISS, Norman: A Maximization Technique Occurring in the Statistical Analysis of Probabilistic Functions of Markov Chains. In: *The Annals of Mathematical Statistics* 41 (1970), Nr. 1, S. 164–171
- [BRD⁺10] BICHI, M.; RIPACCIOLI, G.; DI CAIRANO, Stefano; BERNARDINI, Daniele; BEMPORAD, Alberto; KOLMANOVSKY, Ilya: Stochastic Model Predictive Control with Driver Behavior Learning for Improved Powertrain Control. In: *49th IEEE Conference on Decision and Control (CDC)*. Atlanta: IEEE, 2010, S. 6077–6082
- [BS16] BAEHR, Hans D.; STEPHAN, Karl: *Wärme- und Stoffübertragung*. 9. Auflage. Berlin Heidelberg: Springer Vieweg, 2016
- [Bur17] BURKERT, Andreas: Las Vegas entfesselt die digitale Mobilität. In: *ATZ* 119 (2017), Nr. 3, S. 9–13
- [Bus96] BUSCH, R.: *Entwicklung und Realisierung einer vollautomatischen Betriebsstrategie für einen leistungsorientierten Hybridantrieb*. Aachen, RWTH Aachen, Diss., 1996
- [BZKHK11] BOSSDORF-ZIMMER, Janine; KOLLMER, Hermann; HENZE, Roman; KÜCÜKAY, Ferit: Fingerprint des Fahrers zur Adaption

- von Assistenzsystemen. In: *ATZ* 113 (2011), Nr. 3, S. 226–231
- [Cap11] CAPPÉ, Olivier: Online EM Algorithm for Hidden Markov Models. In: *Journal of Computational and Graphical Statistics* 20 (2011), Nr. 3, S. 728–749
- [Cas13] CASSEBAUM, O.: *Beitrag zum prädiktiven Energiemanagement in Hybridfahrzeugen basierend auf automobilener Standardsensorik*. Dresden, Technische Universität Dresden, Diss., 2013
- [CB11] CASSEBAUM, O.; BÄKER, B.: Predictive Supervisory Control Strategy for Parallel HEVs using Former Velocity Trajectories. In: *2011 IEEE Vehicle Power and Propulsion Conference (VPPC)*. Chicago: IEEE, 2011, S. 1–6
- [CC08] CRYER, Jonathan D.; CHAN, Kung-Sik: *Time Series Analysis*. 2nd ed. New York: Springer, 2008 (Springer Texts in Statistics)
- [CGL83] CHANG, Tony F.; GOLUB, Gene H.; LEVEQUE, Randall: Algorithms for Computing the Sample Variance: Analysis and Recommendations. In: *The American Statistician* 37 (1983), Nr. 3, S. 242–247
- [CLS⁺15] CARVALHO, Ashwin; LEFEVRE, Stephanie; SCHILDBACH, Georg; KONG, Jason; BORRELLI, Francesco: Automated driving: The role of forecasts and uncertainty - A control perspective. In: *European Journal of Control* 24 (2015), S. 14–32
- [CLY⁺11] CHEN, Ling; LV, Mingqi; YE, Qian; CHEN, Gencai; WOODWARD, John: A personal route prediction system based on trajectory data mining. In: *Information Sciences* 181 (2011), Nr. 7, S. 1264–1284
- [CMR05] CAPPÉ, Olivier; MOULINES, Eric; RYDEN, Tobias: *Inference in Hidden Markov Models*. Springer-Verlag New York, 2005 (Springer Series in Statistics)
- [CWKH⁺13] CHING; WAI-KI; HUANG, Ximin; NG, Michael K.; SIU, Tak-Kuen: *International Series in Operations Research & Management Science*. Bd. 189: *Markov Chains: Models, Algorithms and Applications*. 2nd Edition. New York: Springer US, 2013

- [DBBK14] DI CAIRANO, Stefano; BERNARDINI, Daniele; BEMPORAD, Alberto; KOLMANOVSKY, Ilya: Stochastic MPC With Learning for Driver-Predictive Vehicle Control and its Application to HEV Energy Management. In: *IEEE Transactions on Control Systems Technology* 22 (2014), Nr. 3, S. 1018–1031
- [DGG14] DÖRR, Dominik; GRABENGIESSER, David; GAUTERIN, Frank: Online Driving Styles Recognition using Fuzzy Logic. In: *17th International IEEE Conference on Intelligent Transportation Systems*. Qingdao: IEEE, 2014, S. 1021–1026
- [DGT98] DIEBOLD, Francis X.; GUNTHER, Todd A.; TAY, Anthony S.: Evaluating Density Forecasts. In: *International Economic Review* 39 (1998), Nr. 4, S. 863–883
- [Die07] DIEBOLD, Francis X.: *Elements of Forecasting*. Fourth Edition. Cincinnati: Thomson South-Western, 2007
- [DL77] DEMPSTER, A. P.; LAIRD, N. M., RUBIN, D. B.: Maximum Likelihood from Incomplete Data via the EM Algorithm. In: *Journal of the Royal Statistical Society* 39 (1977), Nr. 1, S. 1–38
- [DLK⁺13] DI CAIRANO, Stefano; LIANG, Wei; KOLMANOVSKY, Ilya V.; KUANG, Ming L.; PHILLIPS, Anthony M.: Power Smoothing Energy Management and Its Application to a Series Hybrid Powertrain. In: *IEEE Transactions on Control Systems Technology* 21 (2013), Nr. 6, S. 2091–2103
- [Ebe06] EBERSBACH, Dirk: *Entwurfstechnische Grundlagen für ein Fahrerassistenzsystem zur Unterstützung des Fahrers bei der Wahl seiner Geschwindigkeit*. Dresden, Technische Universität Dresden, Diss., 2006
- [EMW09] ENGELBERG, Joseph; MANSKI, Charles F.; WILLIAMS, Jared: Comparing the Point Predictions and Subjective Probability Distributions of Professional Forecasters. In: *Journal of Business & Economic Statistics* 27 (2009), Nr. 1, S. 30–41
- [FHFG16] FÜNFELD, Sebastian; HOLZÄPFEL, Marc; FREY, Michael; GAUTERIN, Frank: Driver State Estimation for Prediction of Vehicle States Within Control Systems. In: *Proc. 2016 IEEE*

- Intelligent Vehicles Symposium (IV)*. Göteborg: IEEE, 2016, S. 1386–1391
- [FHFG17] FÜNFELD, Sebastian; HOLZÄPFEL, Marc; FREY, Michael; GAUTERIN, Frank: Stochastic Forecasting of Vehicle Dynamics Using Sequential Monte Carlo Simulation. In: *IEEE Transactions on Intelligent Vehicles* 2 (2017), Nr. 2, S. 111–122
- [FK08] FROELICH, Jon; KRUMM, John: Route Prediction from Trip Observations. In: *SAE Technical Paper* Bd. 2008-01-0201. Warrendale: SAE International, 2008
- [FRG⁺11] FRALEY, Chris; RAFTERY, Adrian E.; GNEITING, Tilmann; SLOUGHTER, McLean; BERROCAL, V. J.: Probabilistic Weather Forecasting in R. In: *The R Journal* 3 (2011), Nr. 1, S. 55–63
- [Fuc93] FUCHS, Johann: *Fortschritt-Berichte VDI: Reihe 12, Verkehrstechnik/Fahrzeugtechnik*. Bd. 184: *Beitrag zum Verhalten von Fahrer und Fahrzeug bei Kurvenfahrt*. Düsseldorf: VDI-Verlag, 1993
- [Füß17] FÜSSEL, Andreas: *Technische Potenzialanalyse der Elektromobilität: Stand der Technik, Forschungsausblick und Projektion auf das Jahr 2025*. Springer Fachmedien Wiesbaden, 2017
- [GA17] GOLCHOUBIAN, Parisa; AZAD, Nasser L.: Real-Time Nonlinear Model Predictive Control of a Battery–Supercapacitor Hybrid Energy Storage System in Electric Vehicles. In: *IEEE Transactions on Vehicular Technology* 66 (2017), Nr. 11, S. 9678–9688
- [GBR07] GNEITING, Tilmann; BALABDAOUI, Fadoua; RAFTERY, Adrian E.: Probabilistic forecasts, calibration and sharpness. In: *Journal of the Royal Statistics Society: Series B* 69 (2007), Nr. 2, S. 243–268
- [GGBJ06] GRIMIT, E. P.; GNEITING, Tilmann; BERROCAL, V. J.; JOHNSON, N. A.: The continuous ranked probability score for circular variables and its application to mesoscale forecast ensemble verification. In: *Quarterly Journal of the Royal Meteorological Society* 132 (2006), Nr. 621C, S. 1–17

- [GH06] GOOIJER, Jan G.; HYNDMAN, Rob J.: 25 years of time series forecasting. In: *International Journal of Forecasting* 22 (2006), Nr. 3, S. 443–473
- [Gha01] GHARAMANI, Zoubin: An Introduction to Hidden Markov Models and Bayesian Networks. In: *International Journal of Pattern Recognition and Artificial Intelligence* 15 (2001), Nr. 1, S. 9–42
- [GLP08] GONG, Qiuming; LI, Yaoyu; PENG, Zhong-Ren: Trip-Based Optimal Power Management of Plug-in Hybrid Electric Vehicles. In: *IEEE Transactions on Vehicular Technology* 57 (2008), Nr. 6, S. 3393–3401
- [GMB84] GODTHELP, Hans; MILGRAM, P.; BLAAUW, G. J.: The development of a time-related measure to describe driving strategy. In: *Human Factors* 26 (1984), Nr. 3, S. 257–268
- [GN14] GRANGER, Clive W. J.; NEWBOLD, Paul: *Forecasting Economic Time Series*. New York: Academic Press, 2014
- [Gne08] GNEITING, Tilmann: Editorial: Probabilistic Forecasting. In: *Journal of the Royal Statistical Society, Series A* 171 (2008), Nr. 2, S. 319–321
- [Gne11] GNEITING, Tilmann: Making and Evaluating Point Forecasts. In: *Journal of the American Statistical Association* 106 (2011), Nr. 494, S. 746–762
- [Goß09] GOSSLAU, Dirk: *Vorausschauende Kühlsystemregelung zur Verringerung des Kraftstoffverbrauches*. Cottbus, Universität Cottbus, Diss., 2009
- [GR07] GNEITING, Tilmann; RAFTERY, Adrian E.: Strictly Proper Scoring Rules, Prediction, and Estimation. In: *Journal of the American Statistical Association* 102 (2007), Nr. 477, S. 359–378
- [Gru14] GRUNDITZ, Emma A.: *BEV Powertrain Component Sizing With Respect to Performance, Energy Consumption and Driving Patterns*. Göteborg, Chalmers University of Technology, Diss.,

2014

- [GS12] GOSSLAU, Dirk; STEINBERG, Peter: Vorausschauende Kühlsystemregelung zur Verringerung des Kraftstoffverbrauchs. In: *MTZ* 73 (2012), Nr. 2, S. 162–171
- [GTKD17] GOMOZOV, Oleg; TROVAO, Joao Pedro F.; KESTELYN, Xavier; DUBOIS, Maxime R.: Adaptive Energy Management System Based on a Real-Time Model Predictive Control With Nonuniform Sampling Time for Multiple Energy Storage Electric Vehicle. In: *IEEE Transactions on Vehicular Technology* 66 (2017), Nr. 7, S. 5520–5530
- [GW13] GEWEKE, John; WHITEMAN, Charles: Bayesian Forecasting. In: ELLIOTT, Graham (Hrsg.); TIMMERMANN, Allan (Hrsg.): *Handbook of Economic Forecasting* Bd. 2, Teil A. Amsterdam: Elsevier Science, 2013, S. 3–80
- [HA02] HAGLUND, Mats; ABERG, Lars: Stability in drivers' speed choice. In: *Transportation Research Part F* 5 (2002), Nr. 3, S. 177–188
- [Ham99] HAMBERGER, Werner: *Fortschritt-Berichte VDI: Reihe 12, Verkehrstechnik/Fahrzeugtechnik*. Bd. 371: *Verfahren zur Ermittlung und Anwendung von prädiktiven Streckendaten für Assistenzsysteme in der Fahrzeugführung*. Düsseldorf: VDI-Verlag, 1999
- [Haz11] HAZELTON, Martin L.: Methods of Moments Estimation. In: LOVRIC, Miodrag (Hrsg.): *International Encyclopedia of Statistical Science*. Springer-Verlag Berlin Heidelberg, 2011, S. 816–817
- [Hyn11] HYNDMAN, Rob J.: Forecasting: An Overview. In: LOVRIC, Miodrag (Hrsg.): *International Encyclopedia of Statistical Science*. Springer-Verlag Berlin Heidelberg, 2011, S. 536–539
- [IEC07] IEC 60085:2007-11: *Electrical Insulation - Thermal evaluation and designation*. International Standard (International Electrotechnical Commission), 2007

- [JAE07] JOHANNESSON, Lars; ASBOGARD, Mattias; EGARDT, Bo: Assessing the Potential of Predictive Control for Hybrid Vehicle Powertrains Using Stochastic Dynamic Programming. In: *IEEE Transactions on Intelligent Transportation Systems* 8 (2007), Nr. 1, S. 71–82
- [KAB16] KÖHLER, Christian; APPEL, Dominik; BECK, Hans: Überlebensstrategien im Rennen um vernetzte, autonome Fahrzeuge. In: *ATZ* 118 (2016), Nr. 11, S. 20–25
- [KB03] KARBASSI, A.; BARTH, M.: Vehicle route prediction and time of arrival estimation techniques for improved transportation system management. In: *2003 Intelligent Vehicles Symposium*. Columbus: IEEE, 2003, S. 511–516
- [KD83] KREBS, Hans G.; DAMIANOFF, Nicola: *Forschung Straßenbau und Straßenverkehrstechnik*. Bd. 380: *Geschwindigkeitsverhalten bei Gefahrenzeichen, in Kurven und an Stellen mit Geschwindigkeitsbeschränkung*. Bundesminister für Verkehr, Abt. Straßenbau, 1983
- [KF09] KOLMANOVSKY, Ilya; FILEV, Dimitar P.: Stochastic Optimal Control of Systems with Soft Constraints and Opportunities for Automotive Applications. In: *2009 IEEE Control Applications, (CCA) & Intelligent Control, (ISIC)*. St. Petersburg: IEEE, 2009, S. 1265–1270
- [KLLS14] KASPER, Roland; LEIBHOLD, Roberto; LINDEMANN, Andreas; SCHÜNEMANN, Martin: Elektrische Antriebsmaschinen. In: TSCHÖKE, Hermut (Hrsg.): *Die Elektrifizierung des Antriebsstrangs*. Wiesbaden: Springer Vieweg, 2014 (ATZ/MTZ-Fachbuch), S. 19–49
- [Koh13] KOHLER, T.: *Prädiktives Leistungsmanagement in Fahrzeugbordnetzen*. München, Technische Universität München, Diss., 2013
- [KP15] KUMAR, Mamidi K.; PRASAD, V. K.: Driver Behavior Analysis and Prediction Models: A Survey. In: *International Journal of Computer Science and Information Technologies* 6 (2015), Nr.

4, S. 3328–3333

- [KWH13] KIRCHGÄSSNER, Gebhard; WOLTERS, Jürgen; HASSLER, Uwe: *Introduction to Modern Time Series Analysis*. Second Edition. Springer-Verlag Berlin Heidelberg, 2013 (Springer Texts in Business and Economics)
- [Lem09] LEMIEUX, Christiane: *Monte-Carlo and Quasi Monte-Carlo Sampling*. Springer-Verlag New York, 2009
- [Lie16] LIENKAMP, Markus: *Status Elektromobilität 2016 oder wie Tesla nicht gewinnen wird*. https://www.researchgate.net/publication/304247929_STATUS_ELEKTROMOBILITAT_2016_ODER_WIE_TESLA_NICHT_GEWINNEN_WIRD. Version: 2016, Abruf: 21.04.2017
- [LJEL12] LARSSON VIKTOR; JOHANNESSON, Lars; EGARDT, Bo; LASSON, Anders: Benefit of Route Recognition in Energy Management of Plug-in Hybrid Electric Vehicles. In: *2012 American Control Conference (ACC)*. Montreal: IEEE, 2012, S. 1314–1320
- [LPG04] LIN, C.; PENG, H.; GRIZZLE, J.: A Stochastic Control Strategy for Hybrid Electric Vehicles. In: *2004 American Control Conference (ACC)*. Boston: IEEE, 2004, S. 4710–4715
- [Lud12] LUDWIG, Jürgen: Elektronischer Horizont: Vorausschauende Systeme und deren Anbindung an Navigationseinheiten. In: *ATZelektronik* 7 (2012), Nr. 6, S. 434–439
- [LVL14] LEFÈVRE, Stéphanie; VASQUEZ, Dizan; LAUGIER, Christian: A survey on motion prediction and risk assessment for intelligent vehicles. In: *ROBOMECH Journal* 1 (2014), Nr. 1, S. 1–14
- [LYY⁺16] LI, Liang; YOU, Sixiong; YANG, Chao; YAN, Bingjie; SONG, Jian; CHEN, Zheng: Driving-behavior-aware stochastic model predictive control for plug-in hybrid electric buses. In: *Applied Energy* 162 (2016), S. 868–879
- [Maa15] MAAMRIA, Djamaledine: *Méthodes d'optimisation dynamique de systèmes à plusieurs états pur l'efficacité énergétique auto-*

- mobile*. Paris, École nationale supérieure des Mines de Paris, Diss., 2015
- [Mac03] MACADAM, Charles C.: Understanding and Modeling the Human Driver. In: *Vehicle System Dynamics* 40 (2003), Nr. 1-3, S. 101–134
- [Man85] MANN, K.: *Querbesehleunigung und Querruck in der Übergangsbogenmessung*. Darmstadt, Technische Universität Darmstadt, Diss., 1985
- [Mau11] MAUK, Tobias: *Selbstlernende, zuverlässigkeitsorientierte Prädiktion energetisch relevanter Größen im Kraftfahrzeug*. Stuttgart, Universität Stuttgart, Diss., 2011
- [May14] MAYNE, David Q.: Model predictive control: Recent developments and future promise. In: *Automatica* 50 (2014), Nr. 12, S. 2967–2986
- [Mes16] MESBAH, Ali: Stochastic Model Predictive Control: An Overview and Perspectives for Future Research. In: *IEEE Control Systems Magazine* 36 (2016), Nr. 6, S. 30–44
- [MFCS11] MOURA, Scott J.; FATHY, Hosam K.; CALLAWAY, Duncan S.; STEIN, Jeffrey L.: A Stochastic Optimal Control Approach for Power Management in Plug-In Hybrid Electric Vehicles. In: *IEEE Transactions on Control Systems Technology* 19 (2011), Nr. 3, S. 545–555
- [MG15] MIHALY, Andras; GASPAR, Peter: Driver categorization based on vehicle motion and trajectory data. In: *16th IEEE International Symposium on Computational Intelligence and Informatics*. Budapest: IEEE, 2015, S. 101–105
- [Mic84] MICHON, John A.: A critical view of driver behavior models: what do we know, what should we do. In: EVANS, Leonard (Hrsg.); SCHWING, Richard C. (Hrsg.): *Human Behavior and Traffic Safety*. New York: Plenum Press, 1984, S. 485–520
- [ML99] MORARI, Manfred; LEE, Jay H.: Model predictive control: past, present and future. In: *Computers and Chemical Engineering*

23 (1999), Nr. 4-5, S. 667–682

- [MRP04] MÜLLER, Mark; REIF, Markus; PANDIT, Madhukar: Vehicle Speed Prediction for Driver Assistance Systems. In: *SAE Technical Paper* Bd. 2004-01-0170. Warrendale: SAE International, 2004
- [MSDS12] MERZ, F.; SCIARRETTA, Antonio; DABADIE, J.-C.; SERRAO, L.: On the Optimal Thermal Management of Hybrid-Electric Vehicles with Heat Recovery Systems. In: *Oil & Gas Science and Technology - Rev. IFP Energies nouvelles* 67 (2012), Nr. 4, S. 601–612
- [Mud14] MUDELSEE, Manfred: *Atmospheric and oceanographic sciences library*. Bd. 51: *Climate Time Series Analysis: Classical Statistical and Bootstrap Methods*. 2nd Edition. Cham Heidelberg New York Dordrecht London: Springer, 2014
- [MWN09] MILLS, A.; WILLS, A.; NINNESS, B.: Nonlinear model predictive control of an inverted pendulum. In: *2009 American Control Conference (ACC)*. St. Louis: IEEE, 2009, S. 2335–2340
- [MWP14] MEDER, Jochen; WIEGAND, Thomas; PFADENHAUER, Michael: Adaptive Aerodynamik des neuen Porsche 911 Turbo. In: *ATZ* 116 (2014), Nr. 2, S. 59–64
- [NH03] NICKEL, Markus; HUGEMANN, Wolfgang: Längs- und Querbeschleunigungen im Alltagsverkehr. In: *EVU Conference* Bd. 5. Zürich, 2003
- [NHSS11] NGO, V.; HOFMAN, T.; STEINBUCH, M.; SERRARENS, A.: Predictive gear shift control for a parallel Hybrid Electric Vehicle. In: *2011 IEEE Vehicle Power and Propulsion Conference (VPPC)*. Chicago: IEEE, 2011, S. 1–6
- [OJK⁺16] OKUMURA, Bunyo; JAMES, Michael R.; KANZAWA, Yusuke; DERRY, Matthew; SAKAI, Katsuhiko; NISHI, Tomoki; PROKHOROV, Danil: Challenges in Perception and Decision Making for Intelligent Automotive Vehicles: A Case Study. In: *IEEE Transactions on Intelligent Vehicles* 1 (2016), Nr. 1, S. 20–32

- [PCY⁺16] PADEN, Brian; CAP, Michal; YONG, Sze Z.; YERSHOV, Dmitry; FRAZZOLI, Emilio: A Survey of Motion Planning and Control Techniques for Self-Driving Urban Vehicles. In: *IEEE Transactions on Intelligent Vehicles* 1 (2016), Nr. 1, S. 33–55
- [PDCC13] PADOVANI, Thomas M.; DEBERT, Maxime; COLIN, Guillaume; CHAMAILLARD, Yann: Optimal Energy Management Strategy including Battery Health through Thermal Management for Hybrid Vehicles. In: *IFAC Proceedings Volumes* 46 (2013), Nr. 21, S. 384–389
- [PE07] PLÖCHL, Manfred; EDELMANN, Johannes: Driver models in automobile dynamics application. In: *Vehicle System Dynamics* 45 (2007), Nr. 7-8, S. 699–741
- [Pol14] POLIKARPOVA, Mariia: *Liquid Cooling Solutions for Rotating Permanent Magnet Synchronous Machines*. Lappeenranta, Lappeenranta University of Technology, Diss., 2014
- [Por] PORSCHE AG: *Porsche Active Aerodynamics (PAA): 911 Turbo*. <https://www.porsche.com/usa/models/911/911-turbo-models/chassis/porsche-active-aerodynamics-paa/>, Abruf: 27.08.2019
- [QB03] QIN, S. J.; BADGWELL, T. A.: A Survey of Industrial Model Predictive Control Technology. In: *Control Engineering Practice* 11 (2003), Nr. 7, S. 733–764
- [Rab89] RABINER, L. R.: A tutorial on hidden Markov models and selected applications in speech recognition. In: *Proceedings of the IEEE* 77 (1989), Nr. 2, S. 257–286
- [Rad13] RADKE, Tobias: *Energieoptimale Längsführung von Kraftfahrzeugen durch Einsatz vorausschauender Fahrstrategien*. Karlsruhe, Karlsruher Institut für Technologie, Diss., 2013
- [Ran94] RANNEY, Thomas: Models of Driving Behavior: A Review of their Evolution. In: *Accident Analysis and Prevention* 26 (1994), Nr. 6, S. 733–750

- [RBB⁺08] REISS, C.; BALZER, D.; BRACHT, A.; DUREKOVIC, S.; LÖWENAU, Jan: ADASIS Protocol for Advanced In-Vehicle Applications. In: *15th World Congress on Intelligent Transport Systems*. New York, 2008, 1–15
- [RBD⁺10] RIPACCIOLI, G.; BERNARDINI, Daniele; DI CAIRANO, Stefano; BEMPORAD, Alberto; KOLMANOVSKY, Ilya: A Stochastic Model Predictive Control Approach for Series Hybrid Electric Vehicle Power Management. In: *2010 American Control Conference (ACC)*. Baltimore: IEEE, 2010, S. 5844–5849
- [RH11] ROTHE, R.; HAMEYER, K.: Life Expectancy Calculation for Electric Vehicle Traction Motors Regarding Dynamic Temperature and Driving Cycles. In: *2011 IEEE International Electric Machines & Drives Conference*. Niagara Falls: IEEE, 2011, S. 1306–1309
- [RJ86] RABINER, L. R.; JUANG, B. H.: An Introduction to Hidden Markov Models. In: *IEEE ASSP Magazine* 3 (1986), Nr. 1, S. 4–16
- [RKDB01] REYMOND, Gilles; KEMENY, Andras; DROULEZ, Jaques; BERTHOZ, Alain: Role of Lateral Acceleration in Curve Driving: Driver Model and Experiments on a Real Vehicle and a Driving Simulator. In: *Human Factors* 43 (2001), Nr. 3, S. 483–495
- [RKIA10] RUOHO, Sami; KOLEHMAINEN, Jere; IKÄHEIMO, Jouni; ARKIO, Antero: Interdependence of Demagnetization, Loading, and Temperature Rise in a Permanent-Magnet Synchronous Motor. In: *IEEE Transactions on Magnetics* 46 (2010), Nr. 3, S. 949–953
- [RN09] RUSSELL, Stuart J.; NORVIG, Peter: *Artificial Intelligence: A Modern Approach*. 3rd edition. New Jersey: Pearson Education, 2009 (Prentice Hall Series in Artificial Intelligence)
- [Roy03] ROYAL, Dawn; NATIONAL HIGHWAY TRAFFIC SAFETY ADMINISTRATION (Hrsg.): *National Survey of Speeding and Unsafe Driving Attitudes and Behaviors: 2002: Volume II - Findings Report*. Washington, 2003. (DOT HS 809 688)

- [RSA14] REGUNATH, Sreenath K.; SHARMA, Deepak; ATHREYA, Ashwini S.: Optimal Gearshift Strategy using Predictive Algorithm for Fuel Economy Improvement. In: *SAE Technical Paper* Bd. 2014-01-1743. Warrendale: SAE International, 2014
- [RT01] RUBNER, Yossi; TOMASI, Carlo: *The Springer International Series in Engineering and Computer Science*. Bd. 594: *Perceptual Metrics for Image Database Navigation*. New York: Springer Science & Business Media, 2001
- [Sal16] SALVATORI, Enrico: 5G und Car-to-X: Schlüsseltechniken für den autonomen Straßenverkehr. In: *ATZ elektronik* 11 (2016), Nr. 6, S. 29–32
- [SBS06] SIMMONS, Reid; BROWNING, BRETT; ZHANG, YILU; SADEKAR, Varsha: Learning to Predict Driver Route and Destination Intent. In: *2006 IEEE Intelligent Transportation Systems Conference*. Toronto: IEEE, 2006, S. 127–132
- [Sch82] SCHIMMELPFENNIG, Karl-Heinz: Geschwindigkeiten bei kreisförmiger Kurvenfahrt: Stabilitäts- und Sicherheitsgrenze. In: *Der Verkehrsunfall* 20 (1982), Nr. 5, S. 97–99
- [Sch85] SCHIMMELPFENNIG, Karl-Heinz: Bedeutung der Querbeschleunigung in der Verkehrsunfallrekonstruktion. In: *Verkehrsunfall und Fahrzeugtechnik* 23 (1985), Nr. 4, S. 94–96
- [Sch13] SCHÜTZ, Thomas (Hrsg.): *Hucho - Aerodynamik des Automobils: Strömungsmechanik, Wärmetechnik, Fahrdynamik, Komfort*. 6. Auflage. Wiesbaden: Springer Vieweg, 2013
- [Sei00] SEILER, J.: *Betriebsstrategien für Hybridfahrzeuge mit Verbrennungsmotor unter der Berücksichtigung von Kraftstoffverbrauch und Schadstoffemissionen während der Warmlaufphase*. München, Technische Universität München, Diss., 2000
- [SH13] SCHÜTZHOLD, Jörg; HOFMANN, Wilfried: Analysis of the Temperature Dependence of Losses in Electrical Machines. In: *2013 Energy Conversion Congress and Exposition*. Denver: IEEE, 2013, S. 3159–3165

- [SHL⁺15] SONG, Ziyou; HOFMANN, Heath; LI, Jianqiu; HAN, Xuebing; OUYANG, Minggao: Optimization for a hybrid energy storage system in electric vehicles using dynamic programming approach. In: *Applied Energy* 139 (2015), S. 151–162
- [Spe14] SPECHT, Andreas: *Ermittlung der Rotortemperatur einer Synchronmaschine mit eingebetteten Permanentmagneten für einen automobilen Traktionsantrieb mittels Beobachter basierend auf elektrischen Größen*. Paderborn, Universität Paderborn, Diss., 2014
- [SS11] SHUMWAY, Robert H.; STOFFER, David S.: *Time Series Analysis and Its Applications*. Third Edition. Springer New York Heidelberg Dordrecht London, 2011 (Springer Texts in Statistics)
- [Tao16] TAO, Xinran: *Design, Modeling and Control of a Thermal Management System for Hybrid Electric Vehicles*. Clemson, Clemson University, Diss., 2016
- [TBAMG04] TAUBMAN-BEN-ARI, Orit; MIKULINCER, Mario; GILLATH, Omri: The multidimensional driving style inventory - scale construct and validation. In: *Accident Analysis and Prevention* 36 (2004), Nr. 3, S. 323–332
- [THP⁺10] TÖPLER, Felix; HUANG, Qihui; PAPAJEWSKI, Jens; WILHELM, Christian; SCHACHNER, Markus; GEBHARD, Peter: Prädiktive Leistungsbestimmung für Plug-In Hybridfahrzeuge. In: *19. Aachener Kolloquium Fahrzeug- und Motorentechnik 2010*, 2010, S. 1731–1753
- [TNH⁺15] TANIGUCHI, Tadahiro; NAGASAKA, Shogo; HITOMI, Kentarou; TAKENAKA, Kazuhito; BANDO, Takashi: Unsupervised Hierarchical Modeling of Driving Behavior and Prediction of Contextual Changing Points. In: *IEEE Transactions on Intelligent Transportation Systems* 16 (2015), Nr. 4, S. 1746–1760
- [TW00] TAY, Anthony S.; WALLIS, Kenneth F.: Density Forecasting: A Survey. In: *Journal of Forecasting* 19 (2000), Nr. 4, S. 235–254

- [Val74] VALLENDER, S. S.: Calculation of the Wasserstein Distance Between Probability Distributions on the Line. In: *Theory of Probability & Its Application* 18 (1974), Nr. 4, S. 784–786
- [vG96] VAN WINSUM, Wim; GODTHELP, Hans: Speed Choice and Steering Behavior in Curve Driving. In: *Human Factors* 38 (1996), Nr. 3, S. 434–441
- [Vil09] VILLANI, Cedric: *A Series of Comprehensive Studies in Mathematics*. Bd. 338: *Optimal Transport: Old and New*. Springer-Verlag Berlin Heidelberg, 2009
- [VLZ14] VAITKUS, Vygandas; LENGVENIS, Paulius; ZYLIUS, Gediminas: Driving Style Classification Using Long-Term Accelerometer Information. In: *2014 19th International Conference on Methods and Models in Automation and Robotics (MMAR)*. Miedzydroje: IEEE, 2014, S. 641–644
- [VSP06] VAHIDI, A.; STEFANOPOULOU, A.; PENG, H.: Current Management in a Hybrid Fuel Cell Power System: A Model-Predictive Control Approach. In: *IEEE Transactions on Control Systems Technology* 14 (2006), Nr. 6, S. 1047–1057
- [vW81] VAN DE WATER, H.; WILLEMS, J.: The certainty equivalence property in stochastic control theory. In: *IEEE Transactions on Automatic Control* 26 (1981), Nr. 5, S. 1080–1087
- [Wah15] WAHL, Hans-Georg: *Optimale Regelung eines prädiktiven Energiemanagements von Hybridfahrzeugen*. Karlsruhe, Karlsruher Institut für Technologie, Diss., 2015
- [Wei09] WEISSEL, Florian: *Stochastische modell-prädiktive Regelung nichtlinearer Systeme*. Karlsruhe, Karlsruher Institut für Technologie, Diss., 2009
- [Wel62] WELFORD, B. P.: Note on a Method for Calculating Corrected Sums of Squares and Products. In: *Technometrics* 4 (1962), Nr. 3, S. 419–420
- [Wer10] WERLING, Moritz: *Ein neues Konzept für die Trajektoriengenerierung und -stabilisierung in zeitkritischen Verkehrsszenarien*.

- Karlsruhe, Karlsruher Institut für Technologie, Diss., 2010
- [Wes17] WESTERHOFF, Martin: Fahrzeug 5.0: Die wissensbasierte Maschine. In: *ATZ* 119 (2017), Nr. 1, S. 8–13
- [WH12] WINTER, J.C.F. de; HAPPEE, Riender: Modelling driver behaviour: a rationale for multivariate statistics. In: *Theoretical Issues in Ergonomics Science* 13 (2012), Nr. 5, S. 528–545
- [Wil09] WILDE, Andreas: *Eine modulare Funktionsarchitektur für adaptives und vorausschauendes Energiemanagement in Hybridfahrzeugen*. München, Technische Universität München, Diss., 2009
- [WL11] WANG, Rui; LUKIC, Srdjan M.: Review of Driving Conditions Prediction and Driving Style Recognition Based Control Algorithms for Hybrid Electric Vehicles. In: *2011 Vehicle Power and Propulsion Conference (VPPC)*. Chicago: IEEE, 2011, S. 1–7
- [WLL08] WANG, Aimeng; LI, Heming; LIU, Cheng-Tsung: On the Material and Temperature Impacts of Interior Permanent Magnet Machine for Electric Vehicle Applications. In: *IEEE Transactions on Magnetics* 44 (2008), Nr. 11, S. 4329–4332
- [WXC14] WANG, Wenshuo; XI, Junqiang; CHEN, Huiyan: Modeling and Recognizing Driver Behavior Based on Driving Data: A Survey. In: *Mathematical Problems in Engineering* 2014 (2014), S. 1–20
- [Zai92] ZAIDEL, D. M.: A modeling perspective on the culture of driving. In: *Accident Analysis and Prevention* 24 (1992), Nr. 6, S. 585–597
- [ZBW⁺13] ZHOU, Z.; BOTTERUD, A.; WANG, J.; BESSA, R. J.; SUMAILI, J.; MIRANDA, V.: Application of probabilistic wind power forecasting in electricity markets. In: *Wind Energy* 16 (2013), Nr. 3, S. 321–338
- [ZV12] ZHANG, Chen; VAHIDI, Ardalan: Route Preview in Energy Management of Plug-in Hybrid Vehicles. In: *IEEE Transactions on Control Systems Technology* 20 (2012), Nr. 2, S. 546–553

- [ZW13] ZHAO, Guozhen; WU, Changxu: Mathematical Modeling of Driver Speed Control With Individual Differences. In: *IEEE Transactions on Systems, Man, and Cybernetis: Systems* 43 (2013), Nr. 5, S. 1091–1104
- [ZW15] ZENG, Xiangrui; WANG, Junmin: A Parallel Hybrid Electric Vehicle Energy Management Strategy Using Stochastic Model Predictive Control With Road Grade Preview. In: *IEEE Transactions on Control Systems Technology* 23 (2015), Nr. 6, S. 2416–2423
- [ZXS17] ZHANG, Shuo; XIONG, Rui; SUN, Fengchun: Model predictive control for power management in a plug-in hybrid electric vehicle with a hybrid energy storage system. In: *Applied Energy* 185 (2017), S. 1654–1662