

Fahrerabsichtserkennung und Gefährlichkeitsabschätzung für vorausschauende Fahrerassistenzsysteme

Holger Berndt

Band 16

Holger Berndt

**Fahrerabsichtserkennung und Gefährlichkeitsabschätzung
für vorausschauende Fahrerassistenzsysteme**

Schriftenreihe des
Instituts für Mess-, Regel- und Mikrotechnik
Universität Ulm

Herausgeber:
Prof. Dr.-Ing. Klaus Dietmayer

Band 16

Holger Berndt

Fahrerabsichtserkennung und Gefährlichkeitsabschätzung für vorausschauende Fahrerassistenzsysteme

Bibliografische Information der Deutschen Nationalbibliothek

Die Deutsche Nationalbibliothek verzeichnet diese Publikation in der Deutschen Nationalbibliografie; detaillierte bibliografische Daten sind im Internet über <http://dnb.dnb.de> abrufbar.

Dissertation, Universität Ulm,
Fakultät für Ingenieurwissenschaften, Informatik und Psychologie, 2015

Impressum

Universität Ulm
Institut für Mess-, Regel- und Mikrotechnik
Prof. Dr.-Ing. Klaus Dietmayer
Albert-Einstein-Allee 41
89081 Ulm
<http://www.uni-ulm.de/mrm>

Eine Übersicht über alle Bände der Schriftenreihe finden Sie unter
<http://www.uni-ulm.de/mrmschriften>.

Diese Veröffentlichung ist im Internet auf dem Ulmer Volltextserver (<http://vts.uni-ulm.de>)
verfügbar und dort unter folgender Creative-Commons-Lizenz publiziert:



<http://creativecommons.org/licenses/by-nc-nd/3.0/de/>.

Institut für Mess-, Regel- und Mikrotechnik der Universität Ulm 2016
Print on Demand

ISBN 978-3-941543-20-1

e-ISBN 978-3-941543-21-8



ulm university universität
uulm

**Fahrerabsichtserkennung und
Gefährlichkeitsabschätzung
für vorausschauende Fahrerassistenzsysteme**

DISSERTATION

zur Erlangung des akademischen Grades eines

DOKTOR-INGENIEURS

(Dr.-Ing.)

der Fakultät für Ingenieurwissenschaften, Informatik
und Psychologie der Universität Ulm

von

**Holger Berndt
aus Fulda**

Gutachter: Prof. Dr.-Ing. Klaus Dietmayer
Prof. Dr. rer. nat. Hermann Winner
Amtierende Dekanin: Prof. Dr. Tina Seufert

Ulm, 29.10.2015

Vorwort

Die vorliegende Arbeit entstand während meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Institut für Mess-, Regel- und Mikrotechnik der Universität Ulm.

Mein besonderer Dank gilt Herrn Professor Klaus Dietmayer für die Betreuung dieser Arbeit. Der eingeräumte wissenschaftliche Freiraum, seine wertvollen fachlichen Anregungen, seine konstruktive Kritik und seine Unterstützung während der gesamten Bearbeitungszeit haben wesentlich zum Gelingen der Arbeit beigetragen.

In gleicher Weise gilt mein Dank Herrn Professor Hermann Winner vom Fachgebiet Fahrzeugtechnik der Technischen Universität Darmstadt für die freundliche Übernahme des Koreferates.

Für die angenehme Zusammenarbeit, die vielen fachlichen Diskussionen, gemeinsamen Konferenzbesuche und fortlaufende Unterstützung bedanke ich mich stellvertretend für alle Kollegen des Instituts bei Dr. Stefan Wender, Dr. Andreas Wimmer, Dr. Thomas Szabo, Dr. Thorsten Weiss und Dr. Michael Munz. Mein Dank geht auch an Daniel Schaupp, Alexander Fischer, Jörg Emmert, Jürgen Wünschmann, Leo Vepa, Markus Draxler, Mehrzad Karbaschi und Michael Eder, die im Rahmen ihrer Studiarbeit, Diplomarbeit oder als studentische Hilfskraft tatkräftige Unterstützung geleistet haben.

Für die technische und organisatorische Unterstützung danke ich Franz Degenhardt, Oliver Betz, Martin Niess, Thomas Löffler, Uwe Kerner und Claudia Fricke.

Mein Dank geht auch an die Firma Ibeo Automotive Systems für die intensive und fruchtbare Zusammenarbeit.

Ein ganz besonderer Dank geht an meine Familie, die mir jederzeit zur Seite stand.

Kurzfassung

Assistenzsysteme, die Fahrer vor gefährlichen Situationen warnen sollen, müssen die menschliche Reaktionszeit berücksichtigen. Wird allerdings die Notwendigkeit einer Warnung rein basierend auf Fahrdynamik und Totzeiten abgeschätzt, kommt es je nach Auslegung des Assistenzsystems auch in normalem, als unkritisch empfundenen Situationen zu ungerechtfertigten Warnungen, oder die Warnungen kommen so spät, dass der Nutzen des Assistenzsystems geschmälert wird. Dieses Problem wird unter dem Begriff „Warndilemma“ gefasst.

Die vorliegende Arbeit beginnt mit einer experimentellen Analyse des Warndilemmas. Dabei zeigt sich, dass für Assistenzsysteme mit einem Prädiktionshorizont von mehreren Sekunden zusätzliche Kontextinformationen benötigt werden, um das Warndilemma überwinden und eine verlässliche Warnentscheidung treffen zu können. Die Absicht von Fahrern, ein diskretes Manöver (wie z. B. einen Fahrstreifenwechsel) beginnen zu wollen, wird als wichtiger Faktor bei der Vorhersage einer dynamischen Fahrsituation, die mehrere Sekunden andauert, identifiziert.

In der Folge werden Hidden-Markov-Modelle erfolgreich angewendet, um eine frühzeitige Erkennung eines Manöverbeginns des Fahrzeugs, in dem das Assistenzsystem verbaut ist, zu erreichen. Als Merkmale dienen Signale der Fahrdynamik des Fahrzeugs, digitale Karten und eine kamerabasierte Fahrstreifenenerkennung. Die zugrundeliegenden Markov-Ketten werden auf lineare Modelle beschränkt. Dies ermöglicht es, mit vollständigen Manövern zu trainieren und aus den trainierten Modellen bedeutungstragende Teilmodelle für Manöveranfänge zu extrahieren. Es wird ein Ansatz entwickelt, der es erlaubt, die Manövererkennung rein auf Basis der Produktionswahrscheinlichkeit der Beobachtungen vornehmen zu können. Dekodierung der Beobachtungen sind nicht notwendig. Die lineare Struktur der Markov-Ketten erlaubt es weiterhin, einen „typischen“ Pfad durch das Modell zu bestimmen. Dadurch ergibt sich nicht nur eine noch effizientere Möglichkeit der Klassifikation, sondern auch eine höhere Robustheit gegenüber unterschiedlichen Skalierungen der Merkmale. Ebenfalls werden Einschränkungen durch die bei Markov-Modellen vorliegende geometrische Verteilung der Zustandsübergänge entgegengewirkt. Die Klassifikationsleistung wird durch Vergleich mit einer Grundwahrheit, die durch Markierung aus Testfahrten im öffentlichen Straßenverkehr gewonnen wurde, evaluiert.

Basierend auf probabilistischen Informationen über anstehende Manöver kann eine Trajektorienprädiktion durchgeführt werden. Um die Gefährlichkeit einer sich entwickelnden Situation einschätzen zu können, werden Kollisionswahrscheinlichkeiten abgeschätzt. Da die Berechnung von Kollisionswahrscheinlichkeiten sehr aufwändig ist, werden effiziente Näherungsverfahren entwickelt und ausgewertet.

Abstract

Driver intention recognition and risk assessment for anticipatory driver assistance systems

Advanced driver assistance systems which aim to warn the driver early about dangerous situations must account for the human reaction time. However, when considering physically possible driving dynamics and dead times, the last possible warning time about a potentially upcoming collision is constantly violated even during normal, uncritical driving scenarios. A driver assistance system issuing warnings that solely rely on driving dynamics and dead time would produce an unacceptable amount of false alarms, and would therefore be useless. This problem is known as the “warning dilemma“.

The presented work starts with an experimental analysis of the warning dilemma. Consequences for the design of advanced driver assistance systems are derived from these observations. It is found that in order to develop assistance systems with a prediction horizon of multiple seconds, further context information additionally to driving dynamics is necessary. The intention of drivers to start discrete manoeuvres (like a lane change or a turn manoeuvre) is identified as a major factor determining the dynamic scene within the next couple of seconds.

Statistics show that traffic accidents are caused mainly by human misbehaviour. Oftentimes, performing a manoeuvre that is not adapted to the current traffic situation, or failing to communicate the manoeuvre start to surrounding vehicles results in dangerous situations and crashes. The same applies to the failure of performing a manoeuvre that is required to mitigate an evolving dangerous scenario.

In the presented work, Hidden Markov Models are successfully applied for an early detection of beginning driving manoeuvres. The models use signals of the driving dynamics of the vehicle, digital maps, and a camera-based lane detection as features. By limiting the Markov chains to linear models, it is possible to train complete manoeuvres, and afterwards extract meaningful submodels. The submodels are chosen in a way to fit on manoeuvre starts, in order to ensure early detection. Manoeuvre recognition can be purely based on the probability of the observation

sequence which allows for a computationally efficient classification. Decoding steps are not necessary. The linear structure of the Hidden Markov models also enables the determination of “typical“ paths of an observation sequence through the Markov chain. The result is not only a yet more computationally efficient classification possibility, but also a measure that is more robust in the presence of differently scaled variances of observations and difficulties introduced by the geometrically distributed state transitions inherent to Markov Models. The classification performance is evaluated using a manually labelled reference database of field-recorded driving data.

Based on the probabilistic information about upcoming manoeuvres, a trajectory prediction can be performed. In order to assess the risk of an evolving traffic situation, collision probabilities are evaluated. As determining collision probabilities is a computationally intense operation, efficient approximation methods are proposed and evaluated.

Inhaltsverzeichnis

1	Einleitung	1
1.1	Das Warndilemma der Fahrerassistenz	2
1.2	Aufbau und Inhalt der Arbeit	8
2	Systemüberblick	9
2.1	Thematische Einordnung	9
2.2	Systembeschreibung	11
3	Erkennung der Absicht des Fahrzeugführers	15
3.1	Stand der Technik	15
3.2	Motivation der Methodik	25
3.3	Grundlagen der Mustererkennung mit Hidden-Markov-Modellen	28
3.3.1	Stochastische Prozesse und Markov-Ketten	28
3.3.2	Hidden-Markov-Modelle	29
3.3.3	Produktionswahrscheinlichkeit	32
3.3.3.1	Forward-Algorithmus	33
3.3.4	Optimale Produktionswahrscheinlichkeit	34
3.3.5	Dekodierung	35
3.3.5.1	Maximierung der Anzahl der richtigen individuellen Zustände: Der Forward-Backward-Algorithmus	35
3.3.5.2	Pfad, auf dem die beste Produktionswahrscheinlichkeit erzielt wurde: Der Viterbi-Algorithmus	37
3.3.6	Training	37
3.3.6.1	Training bezüglich der Produktionswahrscheinlichkeit: Der Baum-Welch-Algorithmus	38
3.3.7	Modelltopologie	41
3.3.8	Thematische Einordnung in die Klasse der bayesschen Netze und Analogie zu Kalman-Filter-Modellen	43
3.4	Implementierungsfragen bei HMMs	45
3.4.1	Numerische Stabilität: Logarithmierung und Skalierung von Wahrscheinlichkeiten	45
3.4.2	Minimale Wahrscheinlichkeiten und Modellparameter	47

3.4.3	Skalierung von Emissionen	48
3.5	Modellierung von Fahrmanövern	49
3.5.1	Training mit kompletten Manövern	49
3.5.2	Extraktion von Teilmodellen	49
3.5.3	Typischer Pfad, Zeitfenstergröße und erwarteter Erkennungszeitpunkt	52
3.6	Klassifikationskriterien	53
3.6.1	Modellierung eines Beispielsignals	54
3.6.2	Klassifikation über die optimale Produktionswahrscheinlichkeit	56
3.6.3	Festlegung von Start- und Endzustand	59
3.6.4	Typische Produktionswahrscheinlichkeit	61
3.7	Merkmalsextraktion	63
3.7.1	Digitale Straßenkarten	63
3.7.2	Laterale Position des Fahrzeugs im Fahrstreifen	64
3.7.3	Auswahl der Merkmale	64
3.8	Training der Hidden-Markov-Modelle	66
3.8.1	Trainingsdatenbank	66
3.8.2	Erzeugung der Merkmalsvektoren	68
3.8.3	Auswahl der Modellstrukturparameter	69
3.9	Auswertung der Erkennungsleistung	70
3.9.1	Umfang der Analyse	70
3.9.2	Bewertung der Erkennungsleistung	71
3.9.2.1	Konfusionsmatrizen	72
3.9.2.2	ROC-Kurven	75
3.10	Erkennung von Fahrstreifenwechslern	76
3.10.1	Modelle	76
3.10.2	Ergebnisse für Fahrstreifenwechsel nach links	78
3.10.3	Ergebnisse für Fahrstreifenwechsel nach rechts	80
3.10.4	Diskussion	81
3.10.4.1	Fehler des Klassifikators	81
3.10.4.2	Erkennungszeitpunkt der Manöver	84
3.11	Erkennung von Abbiegemanövern	87
3.11.1	Modelle	87
3.11.2	Ergebnisse für Abbiegemanöver nach links	88
3.11.3	Ergebnisse für Abbiegemanöver nach rechts	90
3.12	Abhängigkeit der Klassifikation vom Fahrer	91
3.13	Vergleichbarkeit der Ergebnisse	91
4	Gefahrenbewertung	93
4.1	Übersicht zur Gefahrenbewertung mit Kollisionswahrscheinlichkeiten	94
4.1.1	Kollisionswahrscheinlichkeit	94

4.1.2	Zeitliche Gewichtung	96
4.1.2.1	Zeitliche Kenngrößen bei deterministischer Prädiktion	97
4.1.2.2	Zeitliche Kenngrößen bei probabilistischer Prädiktion	98
4.2	Annahmen	99
4.3	Bestimmung von Kollisionswahrscheinlichkeiten bei deterministischer Prädiktion	101
4.4	Bestimmung von Kollisionswahrscheinlichkeiten bei Prädiktion mittels Wahrscheinlichkeitsverteilungen	101
4.5	Annäherung mit Monte-Carlo-Sampling	103
4.6	Grid-Ansatz zur Bestimmung von Kollisionswahrscheinlichkeiten über Faltungsoperatoren	106
4.6.1	Aufenthaltswahrscheinlichkeit des Fahrzeugmittelpunktes in jeder Zelle	107
4.6.2	Berücksichtigung der räumlichen Ausdehnung und der Orientierung der Fahrzeuge	108
4.6.3	Berücksichtigung der Unsicherheit der Orientierung	109
4.6.4	Berechnung einer Kollisionswahrscheinlichkeit	110
4.7	Grid-Ansatz zur Bestimmung von Kollisionswahrscheinlichkeiten über Zustandsdiskretisierung	111
4.8	Beschränkung des Einflussbereiches	112
4.9	Abschätzung der Kollisionswahrscheinlichkeit über das Produkt der Wahrscheinlichkeitsdichtefunktionen	114
4.10	Annäherung der Kollisionswahrscheinlichkeit über die Differenz der Positionen	117
4.10.1	Vernachlässigung von Orientierungsunsicherheiten	117
4.10.2	Berücksichtigung der Orientierungsunsicherheit eines Fahrzeugs	119
4.10.2.1	Berechnung einer oberen Schranke für die Kollisionswahrscheinlichkeit	120
4.10.2.2	Berechnung einer unteren Schranke für die Kollisionswahrscheinlichkeit	121
4.10.2.3	Annäherung der Kollisionswahrscheinlichkeit	122
4.10.3	Berücksichtigung der Orientierungsunsicherheit beider Fahrzeuge	124
4.10.3.1	Berechnung einer oberen Schranke für die Kollisionswahrscheinlichkeit über die Kombination von Außenkreis und Außenkreis	124
4.10.3.2	Berechnung einer unteren Schranke für die Kollisionswahrscheinlichkeit über die Kombination von Innenkreis und Innenkreis	125
4.10.3.3	Annäherung der Kollisionswahrscheinlichkeit	125
4.10.4	Berücksichtigung von Orientierungsunsicherheiten durch Winkeldiskretisierung	128

4.11	Auswertung der Methoden zur Bestimmung der Kollisionswahrscheinlichkeit	129
4.11.1	Auswertung des Grid-Ansatzes zur Bestimmung von Kollisionswahrscheinlichkeiten über Faltungsoperatoren . . .	130
4.11.1.1	Summe der Kollisionswahrscheinlichkeiten in den einzelnen Zellen	130
4.11.1.2	Komplementärereignis	131
4.11.2	Auswertung des Grid-Ansatzes zur Bestimmung von Kollisionswahrscheinlichkeiten über Zustandsdiskretisierung .	131
4.11.3	Auswertung der Annäherung der Kollisionswahrscheinlichkeit über das Produkt der Wahrscheinlichkeitsdichten	132
4.11.4	Auswertung der Annäherung der Kollisionswahrscheinlichkeit über die Differenz der Positionen	135
4.11.4.1	Vernachlässigung von Orientierungsunsicherheiten .	136
4.11.4.2	Berücksichtigung der Orientierungsunsicherheit eines Fahrzeugs	137
4.11.4.3	Berücksichtigung der Orientierungsunsicherheit beider Fahrzeuge	137
4.11.4.4	Berücksichtigung der Orientierungsunsicherheit durch Winkeldiskretisierung	138
4.12	Vergleich hinsichtlich Laufzeit und Streuung	139
4.13	Diskussion	141
5	Zusammenfassung	143
A	Herleitungen	145
B	Grundbegriffe der Stochastik	151
	Symbolverzeichnis	155
	Literaturverzeichnis	159
	Publikationen	173
	Betreute studentische Arbeiten	175

Kapitel 1

Einleitung

Mobilität wird als Voraussetzung für hohe Lebensqualität in unserer modernen Gesellschaft angesehen. Ein Großteil der Mobilität wird durch motorisierten Individualverkehr ermöglicht. Im Personenverkehr werden über die Hälfte aller Wege mit dem Kraftfahrzeug erledigt [Sta13], das als Verkehrsmittel insgesamt einen Anteil von über 75% an der Personenbeförderungsleistung, gemessen in Personenkilometern, hält. Der Anteil des über die Straße abgewickelten Güterverkehrs liegt in einer ähnlichen Größe.

Die Nachteile der durch den Straßenverkehr ermöglichten Mobilität bestehen vor allem in Schadstoffemissionen, Lärmbelästigung und hohen Unfallzahlen. Folgerichtig liegen alternative Antriebskonzepte einerseits und Fahrerassistenzsysteme andererseits seit einigen Jahren im Fokus von Forschung und Entwicklung im Automobilbereich.

Im Zuge dieser Entwicklung werden Fahrzeuge mit immer mehr Sensorik ausgestattet, die es dem Fahrzeug erlaubt, sein Umfeld zu erfassen und aktive Sicherheits- und Komfortfunktionen bereitzustellen. Kollisionswarner, automatische Notbremse, Fahrstreifenhaltesysteme oder automatisiertes Parken sind längst in Serienfahrzeugen verfügbar und werden beständig verbessert. Dabei nimmt sowohl die Anzahl der verbauten Assistenzsysteme als auch deren Komplexität immer weiter zu.

Die Verbesserungen spiegeln sich auch in den Unfallstatistiken wider. Neben der Weiterentwicklung der Unfallmedizin werden fortlaufende Verbesserungen der Fahrzeugsicherheit dafür verantwortlich gemacht, dass die Zahl der Verkehrstoten von mehr als 20.000 pro Jahr zu Beginn der siebziger Jahre auf aktuell etwa 4.000 reduziert werden konnte, trotz des deutlichen Anstiegs der Beförderungsleistung im selben Zeitraum.

Trotz dieser Erfolge sind weitere Verbesserungen notwendig. Die Politik in Deutschland hat als Ziel die Verringerung der Anzahl der Verkehrstoten von 2010 bis 2020

um weitere 40% als Ziel ausgegeben [Sta13]. Auch auf europäischer Ebene gibt es diverse Anstrengungen, die Sicherheit im Straßenverkehr zu fördern, beispielsweise mit der im Jahr 2016 anstehenden Aufnahme von diversen aktiven Sicherheitssystemen in das Euro NCAP¹ Bewertungssystem. Durch diese und weitere Maßnahmen soll erreicht werden, dass es 2050 in der Europäischen Union nahezu keine Verkehrstoten mehr gibt [Sta13]. Allerdings wurde zuletzt sogar ein leichter Anstieg der Anzahl der Verkehrstoten für den Beginn des Jahres 2014 in Deutschland gemessen. Auch wenn vor allem gutes Wetter und das dadurch geänderte Mobilitätsverhalten für diesen Anstieg verantwortlich gemacht werden [Sta13], zeigt dies doch, dass noch bedeutende Anstrengungen nötig sind, um die gesteckten Ziele zu erreichen.

Eine Analyse der Unfälle zeigt auf, dass die häufigsten Ursachen in menschlichem Fehlverhalten zu finden sind. Mit gut 90% der durchschnittlich 1,4 Unfallursachen pro Unfall [Sta13] macht menschliches Versagen mit Abstand den größten Anteil aus. Die meisten Unfälle mit Personenschaden werden durch Fehler beim Abbiegen, Wenden, Rückwärtsfahren sowie beim Ein- und Anfahren verursacht. Missachtung der Vorfahrt sowie Fehler bei Fahrstreifenwechseln und zu geringer Abstand sind ebenfalls häufige Auslöser [MEH04; MHE06; Sta13]. Die Entwicklung von Assistenzsystemen konzentriert sich dementsprechend vorrangig auf diese Verkehrssituationen.

1.1 Das Warndilemma der Fahrerassistenz

Assistenzsysteme, die durch eine Warnung des Fahrers gefährlichen Situationen entgegenwirken sollen, sehen sich mit dem *Warndilemma* konfrontiert (z. B. [KE06]): Eine Warnung sollte so spät wie möglich erfolgen, damit der Fahrer nicht bei für ihn augenscheinlich leicht beherrschbaren Fahrszenarien durch unnötige Warnungen gestört wird. Andererseits muss eine Warnung so früh erfolgen, dass der Fahrer Nutzen aus dem Assistenzsystem ziehen und die gefährliche Situation vermeiden oder zumindest entschärfen kann.

Eine Warnung des Fahrers durch ein Assistenzsystem ist nur gerechtfertigt, wenn zwei Bedingungen erfüllt sind: Es muss zum einen eine atypische Fahrsituation und zum anderen eine direkte Gefahr für das eigene Fahrzeug vorliegen, oder das eigene Fahrzeug muss eine direkte Gefahr für andere Verkehrsteilnehmer darstellen.

Zur Unterscheidung von normalen und atypischen Fahrsituationen ist es notwendig, zusätzlich zur dynamischen Modellierung des eigenen Fahrzeugs und des Umfeldes weiteren Kontext zu erfassen. Beispielsweise lässt die rein dynamische Information,

¹NCAP: engl. New Car Assessment Program, standardisiertes Bewertungssystem zum Vergleich der Sicherheit von Neuwagen

dass zwei Fahrzeuge frontal aufeinander zufahren, keine Gefährlichkeitsabschätzung zu. Diese Konstellation kann entweder alltäglich und normal sein (z. B. zwei aufeinander zufahrende Linksabbieger im Kreuzungsbereich im Falle von tangentialem Linksabbiegen) oder hochgefährlich und atypisch (z. B. ein frontal entgegenkommendes Fahrzeug auf dem eigenen Fahrstreifen).

Ein wesentlicher Teil dieses zur Situationsinterpretation erforderlichen Kontextes ist das Verhalten von Verkehrsteilnehmern. Das subjektive Gefährlichkeitsempfinden einer Fahrsituation hängt signifikant davon ab, wie gut andere Verkehrsteilnehmer eingeschätzt werden können und welche Manöver diese Teilnehmer unmittelbar vorhaben.

Aus diesem Grund ist es im Rahmen der Entwicklung von Assistenzsystemen hilfreich, Fahrverhalten zu analysieren. Nur wenn normales Fahrverhalten in einem gegebenen Kontext bekannt ist, ist es möglich, Abweichungen von dieser Norm zu erkennen und die Evolution einer atypischen Situation im Voraus abzuschätzen.

Sandblom und Brännström postulieren in [SB11], dass ein Fahrer als Kollisionsvermeidungssystem modelliert werden kann. Genau wie bei maschinellen Systemen erfassen Fahrer ihr Umfeld, präzisieren erkannte Objekte und planen Bahnen mit gewissen Mindestabständen. Auch die für maschinelle Systeme typischen Unsicherheiten bei der Umfeldmodellierung sowie bei der Prädiktion sind auf Menschen übertragbar, ebenso prinzipielle sensorische Schwächen wie begrenzte Erfassungsbereiche. Das Ziel des Systems von Sandblom und Brännström ist es, die Akzeptanz des Fahrers für eine Warnung eines Assistenzsystems beständig mitzuschätzen und dadurch das Warndilemma zu entschärfen und frühere Warnzeitpunkte zu ermöglichen. Die Grundidee ist, dass ein Fahrer eine Warnung (auch im Nachhinein) eher akzeptiert, wenn er selbst die Situation als kritisch einstuft. Um diese Einstufung abschätzen zu können, werden einerseits Schwellwertabschätzungen bezüglich der Schwere eines Manövers, was die Situation vermeidet, vorgenommen. Andererseits werden probabilistische Hypothesentests durchgeführt, die auf angenommenen Umfeld- und Prädiktionsunsicherheiten beruhen. So kann abgebildet werden, dass ein Mensch eine Situation, die für ihn selbst schwierig vorhersehbar ist (z. B. spielende Kinder), als vergleichsweise kritisch einschätzt. Notwendig für diesen Ansatz sind neben einer funktionierenden sensorischen Umfelderkennung realistische Abschätzungen der Unsicherheiten, insbesondere der Prädiktionsunsicherheiten.

In den vergangenen Jahren wurden verschiedene Untersuchungen zur Messung und Modellierung von Fahrverhalten durchgeführt. Meist werden diese Daten mithilfe von Probandenversuchen in Simulatoren, mithilfe von Testfahrten in speziell ausgerüsteten Fahrzeugen oder durch eine Kombination dieser Methoden gewonnen. Vollrath und Rataj z. B. verbinden Fahrversuche in einem Versuchsträger mit Versuchen im Simulator, um einerseits reale Daten aufzunehmen und andererseits gefährliche

Manöver wie das Einschlafen eines Fahrers ohne reale Gefährdung am Simulator nachstellen zu können [VR05]. Es ist jedoch sehr aufwändig, mit diesem Ansatz durchschnittliches Fahrverhalten über eine größere Stichprobe von Fahrern hinweg zu erfassen. An den Versuchen der genannten Publikation waren sechs Fahrer beteiligt.

Der alternative Ansatz, Daten durch Beobachtung von öffentlichem Straßenverkehr zu sammeln, wurde bisher weniger häufig verfolgt. Im Gegensatz zu Probandenversuchen hat dies den Vorteil, dass eine größere Anzahl unterschiedlicher Fahrer und Fahrzeugtypen berücksichtigt werden kann. Darüber hinaus ist es eher möglich, natürliches Fahrverhalten zu beobachten, wenn die Testpersonen sich nicht bewusst sind, dass Daten erfasst werden und sie keinen speziellen Versuchsträger nutzen müssen. Andererseits ist die Datenerhebung schwieriger, da weder Simulatordaten ausgewertet noch einfach zugängliche Sensorik eines Versuchsträgers ausgelesen werden können.

Klanner et. al. untersuchen unter anderem die im normalen Verkehr akzeptierten Zeitlücken beim Einbiegen/Kreuzen und Linksabbiegen durch Beobachtung des Kreuzungsgeschehens mit einer Videokamera [KEW06; KTW08]. So konnte beispielsweise herausgefunden werden, dass in den beobachteten Szenarien beim Kreuzen keine Zeitlücken unter 2,5 s auftraten.

Mages untersucht das Fahrverhalten in Kreuzungsbereichen mithilfe von in Mülltonnen verbauten Radarsensoren [Mag08; MHW07]. Hier wird insbesondere die Abhängigkeit des Fahrverhaltens von Kreuzungsparametern wie Vorfahrtregelungen und Sichtverdeckung analysiert. Untersucht wird der Bremsbeginn vor der Kreuzung, gemessen in TTI (Time To Intersection). Dabei stellte sich heraus, dass sich die Beherrschung des Warndilemmas insbesondere an Vorfahrt-Achten-Kreuzungen als äußerst schwierig gestaltet.

Mabuchi und Yamada untersuchen in [MY11] die Entscheidung von Fahrern, an gelben Ampeln anzuhalten oder noch durchzufahren. Dazu werden Daten von Probandenversuchen in einem Simulator über Support Vector Machines klassifiziert. Als Eingänge dienen die Position des Fahrzeugs relativ zur Ampel sowie Geschwindigkeit und Beschleunigung des Fahrzeugs und die Zeit seit Umschalten der Ampel von grün auf gelb. In einer weiteren Studie [MY13] wird auf eine in Fahrversuchen in realem Verkehr aufgenommene Datenbasis umgestellt. Eine Support Vector Machine wird mit Featurevektoren bestehend aus den beschriebenen Eingängen trainiert. Mit dieser Methode sollen Durchfahr- oder Anhaltevorgänge zum Zeitpunkt des Umschaltens der Ampel vorhergesagt werden, also i.Allg. bevor der Fahrer seine Entscheidung fällen konnte. Darüber hinaus beobachten die Autoren die Dynamik des Fahrzeugs bei der weiteren Anfahrt, um Rückschlüsse auf die Willensbildung des Fahrers zu erhalten. In diesem Ansatz wird ebenfalls eine Support Vector Machine genutzt. Bis zu einer Distanz von 6 m vor der Kreuzung beim Umschaltezeitpunkt konnte das

Verhalten ohne Fehler vorhergesagt werden, in größerer Entfernung kam es zu einer steigenden Zahl von Fehlklassifikationen.

Ebenfalls für Annäherungsvorgänge an Ampeln untersucht Ortiz in [OFKG11] die Möglichkeiten, die Verhaltens-Primitive „bremsen“, „gestoppt“ und „konstante Fahrt“ für einen Zeitraum von bis zu 6 s vorherzusagen. Die Vorhersage basiert auf dem dynamischen Zustand des Fahrzeugs sowie der Position und der Phase der Ampel, die mit einem neuronalen Netz ausgewertet werden.

Die Klassifikation von Fahrverhalten an Ampeln in „regelkonform“ und „regelverletzend“ basierend auf Support Vektor Machines kombiniert mit bayesscher Filterung [KA06] einerseits und Hidden-Markov-Modellen andererseits wird in [ADSH11] verglichen. Dabei konnte auf eine große Zahl von Anfahrtrajektorien zurückgegriffen werden, die im Rahmen des „Cooperative Intersection Collision Avoidance System for Violations“ [DOT08] Projektes der US Verkehrsbehörde DOT² gesammelt wurden. Beide Verfahren lieferten vergleichbare Ergebnisse für diese Aufgabenstellung, wobei Support Vector Machines Vorteile bei sehr kleinen Falschalarmraten aufwiesen, wogegen Hidden-Markov-Modelle bessere Detektionsraten erreichen konnten.

In eigenen Voruntersuchungen wurde das Annäherungsverhalten von Fahrern an eine rote Ampel durch Verkehrsbeobachtung betrachtet [BWD07]. Die Daten wurden durch Objekttrackingverfahren basierend auf einem Laserscanner gewonnen und über Entfernungs-/Geschwindigkeitsdiagramme ausgewertet. Abb. 1.1 stellt das Warndilemma auf dieser Datenbasis dar.³ Dargestellt sind in durchgezogenen Kurven die Einhüllenden der beobachteten Fahrtrajektorien als 50%, 97% und 100% Quantile. Zusätzlich ist als gepunktete Linie die simulierte Trajektorie einer Notbremsung mit einer konstanten Verzögerung von $9 \frac{m}{s^2}$ gezeigt. Die gestrichelte Linie beschreibt die Grenzkurve, unterhalb der bei einer kombinierten Reaktionszeit von Fahrer und Bremssystem von 1,5 s eine Notbremsung das Fahrzeug gerade noch vor der Kreuzung zum Stehen bringen würde. Fahrer, die diese Kurve durchbrechen, könnten bei den angenommenen Werten für Reaktionszeit und Maximalverzögerung nicht mehr rechtzeitig auf eine Warnung reagieren.

Abb. 1.1 zeigt, dass ein sehr großer Anteil an Fahrern bei Fahrten, für die ein Fahrerassistenzsystem keine Warnung erzeugen darf, diese Kurve zum Teil deutlich und früh schneiden.⁴ Das Durchbrechen der Grenzkurve kann also nicht als alleiniges Merkmal für ein warnendes System genutzt werden. Es besteht offensichtlich Bedarf, weitere Kriterien einfließen zu lassen, die auf eine atypische Situation schließen

²DOT: engl. Department of Transportation

³Für detaillierte Auswertungen hinsichtlich der Objektdistanz zum Umschaltzeitpunkt der Ampel, Fahrzeugklassen und Wetterbedingungen sowie eine Validierung der Trackinggenauigkeit für das beobachtete Szenario sei auf [BWD07] verwiesen.

⁴Die Datenbasis enthielt keine für den Beobachter als gefährlich erscheinende Situation.

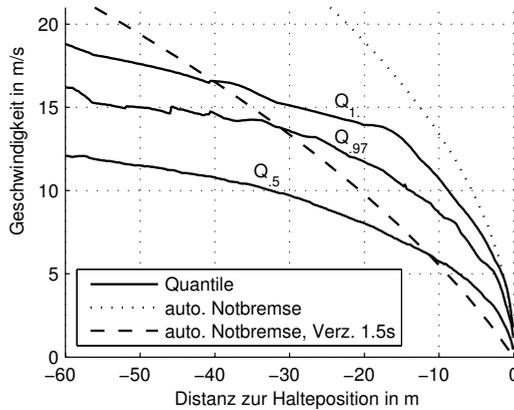


Abbildung 1.1: Untersuchung zum Warndilemma beim Anhalten an einer roten Ampel [BWD07]. Gezeigt sind die 50%, 97% und 100% Quantile der beobachteten Fahrer sowie Kurven für Notbremsungen mit und ohne Verzögerung (Verz.) durch Reaktionszeit.

lassen. In diesem Fall wäre das die möglichst frühzeitige Erkennung der Absicht des Fahrzeugführers, ein erwartetes Manöver (eine Bremsung an einer roten Ampel) rechtzeitig auszuführen zu wollen. Nur wenn die Situation durch den Fahrer nicht mehr beherrschbar erscheint, weil das erwartete Manöver nicht oder zu spät eingeleitet wird, ist ein Eingriff durch ein Assistenzsystem gerechtfertigt. Zusätzlich zur sensorischen Umfelderkennung und dynamischen Prädiktion ist also auch eine Berücksichtigung des mentalen Fahrerzustandes nötig, um das Warndilemma zu beherrschen.

Für den Fall, dass Fehlverhalten eines anderen Fahrzeugs das eigene Fahrzeug gefährdet, ergeben sich noch höhere Anforderungen an Assistenzsysteme. Beispielhaft sei eine Vorfahrt-Achten-Kreuzung mit Querverkehr betrachtet, wobei das Sensorfahrzeug Vorfahrt hat. Selbst wenn die Objektverfolgung des Querverkehrs ideale Ergebnisse liefert, kann ein Assistenzsystem erst dann warnen, wenn es wahrscheinlich ist, dass der Querverkehr seiner Haltepflcht nicht nachkommen wird, wenn also ein atypisches Verhalten des Querverkehrs festgestellt wurde. Dies kann z. B. durch Vergleich der Trackingergebnisse mit einem 100% Quantil analog zu Abb. 1.1 geschehen, sofern eine entsprechend große Stichprobe als Datenbasis zugrunde liegt, die Generalisierung auf den betrachteten Anwendungsfall plausibel erscheinen lässt. Als Beispiel sei angenommen, dass das Fehlverhalten des anderen Verkehrsteilnehmers festgestellt wurde, als dieser sich 10 m vor der Kreuzung befand. Das Fahrzeug bewegt sich in diesem Beispiel nach Q_1 aus Abb. 1.1 mit ca. $11 \frac{\text{m}}{\text{s}}$ auf die Kreuzung

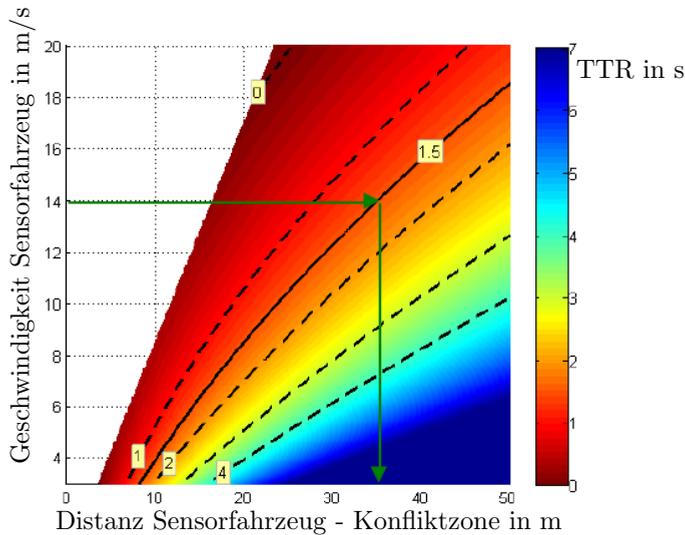


Abbildung 1.2: Verbleibende Reaktionszeit (Time To React, TTR) bis zu einer Vollbremsung, die den Querverkehrsunfall gerade noch vermeiden würde, unter der Annahme, dass das Fehlverhalten des querfahrenden Fahrzeugs 10 m vor der Kreuzung festgestellt wurde. Die TTR in Sekunden ist farbcodiert über Position und Geschwindigkeit des Sensorfahrzeugs aufgetragen.

zu. Weiter sei angenommen, dass das Fahrzeug nur leichte Längsbeschleunigungen von bis zu $\pm 2 \frac{\text{m}}{\text{s}^2}$ ausführt.

Das Potential eines Assistenzsystems im Sensorfahrzeug in dieser konkreten Situation ist abhängig von der Position des Sensorfahrzeugs relativ zur Konfliktzone in der Kreuzung, von seiner Geschwindigkeit sowie von der kombinierten Reaktionszeit des Fahrers und Bremssystems. Abb. 1.2 zeigt diesen Zusammenhang graphisch. Fährt das Sensorfahrzeug beispielsweise mit $14 \frac{\text{m}}{\text{s}}$ und wird eine Reaktionszeit von 1,5 s angenommen, muss das Fehlverhalten bereits 35 m vor der Konfliktzone erkannt werden.

Dieses Szenario stellt sehr hohe Anforderungen an die Umfelderkennung des Sensorfahrzeugs. Selbst bei angenommenem idealem Tracking ist es meist durch Sichtverdeckungen im Kreuzungsbereich nicht möglich, Fehlverhalten aus der geforderten Entfernung zu entdecken.

Könnte andererseits die fehlende Absicht, Vorfahrt zu achten, im querfahrenden Fahrzeug erkannt werden, bestünde die Möglichkeit eines Bremsingriffes zur Entschärfung der Situation. Da das Ergebnis einer Fahrerabsichtserkennung bezüglich anstehender oder ausbleibender Manöver ein Signal mit hohem Informationswert und niedriger benötigter Bandbreite ist, ist es außerdem für Drahtloskommunikation gut geeignet. Eine Verbreitung dieser Information über Fahrzeug-zu-Fahrzeug- oder Fahrzeug-zu-Infrastruktur-Kommunikation könnte das Wirkpotential von kooperativen Fahrerassistenzsystemen [AAZ13; EK06; MAB⁺11; SA06] erhöhen.

Zusammenfassend kann festgestellt werden, dass eine Abschätzung der Absicht, Manöver einleiten zu wollen, für Fahrerassistenzsysteme im eigenen oder umgebenen Fahrzeugen eine wertvolle Information darstellt. Mit Hilfe einer Fahrerabsichtserkennung kann das Warndilemma überwunden werden. Erkannte anstehende Manöver stellen eine Fahrsituation in einen semantischen Kontext, und unterstützen Assistenzsysteme, in einem regelbasierten System wie dem Straßenverkehr korrekte Entscheidungen zu treffen. Das Problem der frühzeitigen Manövererkennung ist jedoch noch nicht gelöst. Vor allem in diesem Bereich soll durch die vorliegende Arbeit ein Beitrag geleistet werden.

1.2 Aufbau und Inhalt der Arbeit

Kapitel 2 gibt einen Überblick über das in dieser Arbeit entwickelte System zur Situationsbewertung im Straßenverkehr. Es erfolgt eine Dekomposition in die aufeinander aufbauenden Verarbeitungsschritte *Absichtserkennung des Fahrers*, *Trajektorienprädiktion* und *Gefahrenbewertung*.

Kapitel 3 beschäftigt sich mit der frühzeitigen Erkennung von Fahrmanövern. Beginnend mit einer Übersicht über den Stand der Technik auf dem Gebiet der Interaktion von Fahrer und Fahrerassistenzsystem werden die methodischen Ansätze zur Manövererkennung motiviert und die entwickelten Verfahren detailliert beschrieben. Das Kapitel endet mit einer Auswertung, in der die Leistungsfähigkeit der Verfahren analysiert wird.

Kapitel 4 behandelt die Auswertung einer Kollisionswahrscheinlichkeit als Kriterium für die Gefährlichkeit einer Fahrsituation. Da die Bestimmung dieses Maßes im Allgemeinen aufwändig ist, werden recheneffiziente Näherungsverfahren vorgestellt.

Kapitel 2

Systemüberblick

2.1 Thematische Einordnung

Bei der Bewertung der Leistung eines Menschen, eine Aufgabe zu erledigen, wird in der Verhaltensforschung zwischen verschiedenen, miteinander interagierenden Verhaltenskategorien unterschieden. Je nachdem, welches kognitive Level die Aufgabe erfordert, unterscheidet beispielsweise Rasmussen in [Ras83] zwischen *fähigkeitsbasiertem*, *regelbasiertem* und *wissensbasiertem* Verhalten. Unter fähigkeitsbasiertem Verhalten wird dabei unbewusstes sensorisch-motorisches Handeln verstanden, das vom Körper weitgehend automatisch umgesetzt wird. Auslöser ist eine Intention, eine bestimmte Aufgabe zu erledigen. Verschiedene Sequenzen von fähigkeitsbasiertem Verhalten können aneinandergesetzt werden, um ein komplexeres, erlerntes Ziel zu erreichen. Diese Kopplung gleicht einer regelbasierten Steuerungsaufgabe und stellt das nächsthöhere kognitive Level dar. Wird ein Mensch vor neue Aufgaben gestellt, für die noch keine Regeln erlernt werden konnten, müssen bewusst Strategien zur Problemlösung erstellt werden, deren Analyse¹ in einem Regelwerk zur Bewältigung der Aufgabe mündet. Dieses Vorgehen wird von Rasmussen als wissensbasiertes Verhalten bezeichnet.

Speziell für das Fahrverhalten gibt es ganz ähnliche Ansätze. So unterscheidet Michon [Mic85] zwischen drei hierarchischen, nur vergleichsweise lose verkoppelten Ebenen (Abb. 2.1): Der *strategischen*, der *taktischen* und der *operationellen* Ebene.

Auf der strategischen Ebene finden vor allem längerfristige Planungsaufgaben statt. Dort wird beispielsweise die Route festgelegt, basierend auf Überlegungen hinsichtlich Kosten, Zeitaufwand, Komfort, Kraftstoffoptimalität und anderen Kriterien.

¹beispielsweise durch die Methode von Versuch-und-Irrtum oder durch Abwägung aller Handlungsoptionen und ihrer Kosten zur Erreichung des Ziels

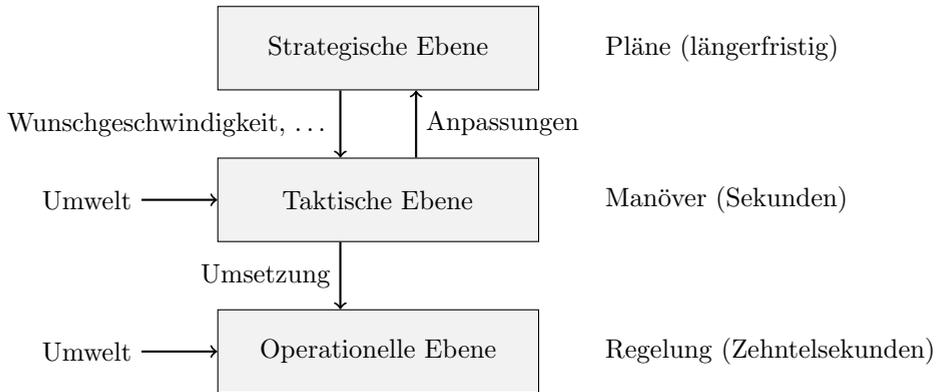


Abbildung 2.1: Hierarchische Struktur des Fahrverhaltens nach [Mic85]. Die einzelnen Ebenen sind nur lose verkoppelt. Rückkopplungen von der operationellen Ebene auf die taktische Ebene sind zwar vorhanden (z. B. Abbruch eines Manövers aufgrund unzureichender Motorleistung), aber nicht dominant.

Die taktische Ebene umfasst kurzfristige² Handlungen und Fahrmanöver, durch die die strategischen Ziele erreicht werden sollen. Zu beachten ist, dass es eine beidseitige Verkopplung mit der strategischen Ebene gibt. So kann z. B. der Plan bestimmen, welche Wunschgeschwindigkeit der Fahrer vorzieht oder welche Risikobereitschaft er zeigt. Anders herum kann ein Plan geändert werden, wenn unvorhergesehene Umstände (z. B. ein Verkehrsstau) die taktische Umsetzung des Plans verhindern.

Die operationelle Ebene beinhaltet regelungstechnische Aufgaben (wie die Fahrzeugstabilisierung) oder Führungsaufgaben (wie die richtige Wahl von Pedalstellungen und Lenkbewegungen), um ein Manöver wie vom Fahrer gewünscht durchzuführen. Die Rückkopplung innerhalb der Ebene erfolgt hier im Bereich von Zehntelsekunden.

Eine Erkennung des Fahrverhaltens kann auf strategischer, taktischer und operationeller Ebene geschehen. Für die Erkennung auf strategischer Ebene ist im Allgemeinen eine längere Beobachtungsdauer oder eine explizite Bekanntgabe des Ziels durch den Fahrer³ nötig, um Rückschlüsse auf den aktuellen Plan ziehen zu können [DR02]. Andererseits sind durch längere Beobachtungen auch plan-unspezifische generelle Fahrereigenschaften („fährt vorsichtig“, „fährt gerne schnell“...) ableitbar. In beiden Fällen gilt, dass nach richtiger Erkennung zwar das prinzipiell in Zukunft zu erwartende generelle Fahrverhalten, aber nicht einzelne dynamische Zustandsgrößen

²im Zeitbereich von einigen Sekunden

³z. B. über das Navigationssystem

verlässlich geschätzt werden können.

Die Erkennung des Fahrverhaltens auf taktischer Ebene entspricht einer Manöverdetektion. Diese findet auf einer viel kleineren Zeitskala statt, so dass eine kurzzeitige Beobachtung des Fahrers ausreicht. Da Manöver nur wenige Sekunden andauern, ist damit auch nur ein entsprechend kleiner Prädiktionshorizont von einigen Sekunden möglich, für den jedoch dynamische Zustandsgrößen geschätzt werden können.

Alternativ zur Erkennung von klar definierten, diskreten Verhaltensweisen auf der taktischen Ebene und Auswertung dieser Information kann eine Bewertung einer Situation auch durch kontinuierliche Betrachtungen dynamischer Größen ohne direkte Klassifizierung erfolgen. In [HEH⁺10; HWSK09] beispielsweise werden kürzlich abgefahrene Trajektorien-Stücke verwendet, um anhand von gelernten Daten die Trajektorie in den nächsten Sekunden vorherzusagen. Diskrete Manöver kommen hier nur implizit und in dem Maße vor, wie sie in den gelernten Daten enthalten waren.

Verhaltenserkennung auf operationeller Ebene befasst sich mit der Analyse und Vorhersage von Steuereingängen des Fahrers während einer gegebenen Fahrsituation.

Assistenzsysteme, die den Fahrer in potentiell gefährlichen Situationen unterstützen sollen, profitieren insbesondere von Kontextinformationen bezüglich der taktischen Ebene. Informationen darüber, welche Manöver die an einer Verkehrssituation beteiligten Fahrzeuge in den nächsten Sekunden ausführen werden, ermöglicht Modellbildung, Analyse und Bewertung der Situation als Grundlage für die Entscheidungsfindung von Assistenzsystemen.

2.2 Systembeschreibung

In den folgenden Kapiteln dieser Arbeit werden Methoden zur Erstellung eines Systems für die Situationserkennung und -bewertung auf taktischer Ebene im Straßenverkehr vorgestellt. Das System wird top-down in drei Module dekomponiert, die jeweils einen Teilbereich der Aufgabe bearbeiten und über klar abgegrenzte Schnittstellen miteinander interagieren: Absichtserkennung, Trajektorienprädiktion und Gefahrenbewertung. Das Zusammenspiel der Module ist in Abb. 2.2 dargestellt.

Motiviert von der Tatsache, dass der Straßenverkehr ein regelbasiertes System ist, wird zunächst eine Absichtserkennung für Manöver durchgeführt. Diese findet im Rahmen der vorliegenden Arbeit ausschließlich auf taktischer Ebene statt, d.h. es werden diskrete Manöver wie Fahrstreifenwechsel und Abbiegevorgänge im Sekun-

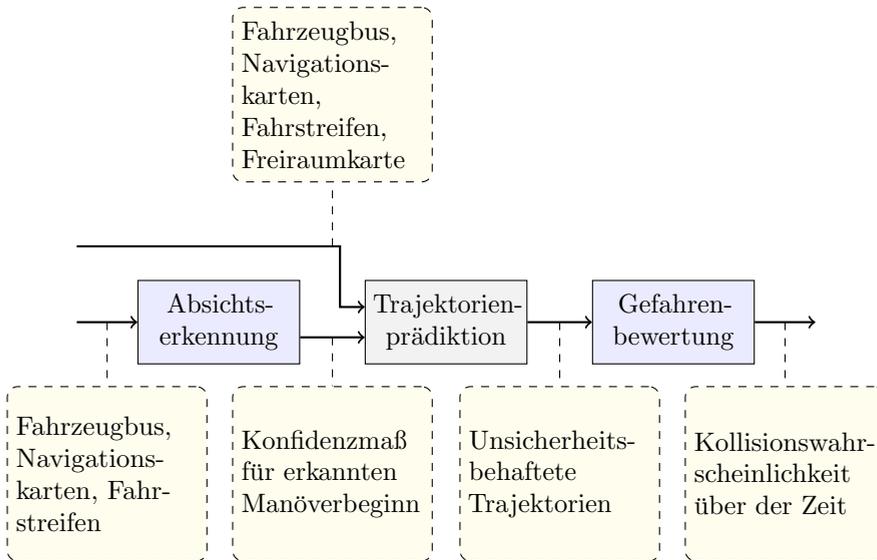


Abbildung 2.2: Überblick über das System mit den Teilsystemen und ihren Schnittstellen. Vom Fahrzeugbus können dynamische Zustandsgrößen (z. B. Geschwindigkeit oder Gierrate), sowie Informationen über Steuereingänge (z. B. Lenkwinkel oder Pedalstellungen) erhalten werden.

denbereich erkannt. Als Eingang dienen Signale vom CAN-Bus wie Geschwindigkeit, Gierrate oder Lenkwinkel, sowie Kontext-Informationen aus einer Navigationskarte und einer Fahrstreifenenerkennung. Die Absichtserkennung stellt fortlaufend für alle zu erkennenden Manöver ein Konfidenzmaß bereit, das aussagt, mit welcher Sicherheit das entsprechende Manöver gerade beginnt. Zu beachten ist, dass für die Weiterverarbeitung der Ergebnisse keine diskrete Klassifikation über eine Schwellwertbildung vorgenommen werden muss, auch wenn dies für eine Beurteilung des einzelnen Moduls im Rahmen dieser Arbeit hilfreich ist. Dem gegenüber ist es in einem Gesamtsystem vorteilhaft, die probabilistische Information in übergeordneten Schichten nutzen zu können [BWKS13; Mah09].

Die Aufgabe der Trajektorienprädiktion ist, eine probabilistische Aussage über zukünftige Aufenthaltsorte von Objekten zu treffen. Das Modul benutzt dafür i.Allg. zusätzlich zu den Ergebnissen der Absichtserkennung diverse Informationsquellen. Der dynamische Zustand des eigenen Fahrzeugs ist auf dem CAN-Bus⁴ verfügbar. Aus der Positionierung mit GPS in Navigationskarten kann ein grober Kreuzungsbereich

⁴oder über ein Trackingverfahren für Objekte, die mit Umgebungssensoren erfasst wurden [BKL01]

abgeschätzt werden, mit einer Freiraumkarte kann Wissen über den befahrbaren Bereich im unmittelbaren Umfeld berücksichtigt werden [WSD07]. Das Ergebnis der Trajektorienprädiktion ist je nach Methode und verfügbaren Signalen eine zeitliche Folge von Punktwolken, Aufenthaltsorten mit parametrischen Dichteverteilungen oder Aufenthaltsorten mit gridbasierten Dichteverteilungen.

Im Modul zur Gefahrenbewertung werden die Trajektorien hinsichtlich einer Kollisionswahrscheinlichkeit ausgewertet. Andere Bewertungskriterien kommen in der Arbeit nicht zum Einsatz. Da die Bestimmung einer Kollisionswahrscheinlichkeit i.Allg. eine sehr komplexe Aufgabe ist, liegt die Herausforderung vor allem darin, möglichst recheneffiziente Näherungsverfahren zu finden. Die Methoden, die dabei Anwendung finden, hängen von der Repräsentation der probabilistischen Trajektorie ab, die vom Prädiktionsmodul übergeben wurde.

Die vorliegende Arbeit konzentriert sich vorrangig auf den Teilbereich der Absichtserkennung, für den ein neuartiges Verfahren entwickelt wird. Darüber hinaus werden Beiträge zur Gefahrenbewertung geleistet. Für die Behandlung der Prädiktionsaufgabe sei auf die umfangreiche Literatur verwiesen, z. B. [Bor13; HNR68; SMB03; WHKD12].

Kapitel 3

Erkennung der Absicht des Fahrzeugführers

In diesem Kapitel wird ein System zur Erkennung der Absicht von Fahrern von Personenkraftwagen, ein Fahrmanöver auf taktischer Ebene einzuleiten, vorgestellt. Speziell handelt es sich bei den zu erkennenden Manövern um Abbiegevorgänge sowie Fahrstreifenwechsel auf Straßen mit mehreren Fahrstreifen in Fahrtrichtung. Die Fahrmanöver können jeweils nach links oder rechts ausgeführt werden. Diese vier Manöver sollen von normaler Fahrt auf dem Fahrstreifen unterschieden und möglichst früh während ihrer Entstehungsphase erkannt werden.

3.1 Stand der Technik

In den vergangenen Jahren gab es vielfältige Forschungs- und Entwicklungstätigkeiten im Bereich der automotiven Assistenzsysteme, die ihren Fokus auf den Faktor Mensch richten. Die Interaktion von Mensch und Assistenzsystem kann dabei unterschiedliche Formen annehmen.

Die Zielsetzungen, aber auch die Ansätze und Methoden der Untersuchungen von Mensch-Fahrzeug-Schnittstellen sind mannigfaltig. Eine einheitliche Nomenklatur hat sich dabei noch nicht herausgebildet, so dass beim Vergleich im Umgang mit den Begrifflichkeiten Vorsicht geboten ist. Grundlegende Kriterien zur Kategorisierung der Arbeiten über Fahrverhalten sind:

Zweck

Ein System zur Analyse von Fahrverhalten kann aus unterschiedlichen Gründen aufgebaut werden. Neben dem Wunsch, durch das System Fahrtrajektorien vorherzusagen und eine Gefährlichkeitsabschätzung durchführen zu können, kann

beispielsweise auch der Wunsch einer Online-Fahrertypisierung zur Parametrierung von Assistenzsystemen im Vordergrund stehen oder die Verbesserung von Fahr simulatoren durch detaillierte Verhaltensmodelle. Intuitivere Konzepte für die Mensch-Maschine-Schnittstelle können ebenfalls von Fahreranalysen profitieren.

Ebene

Die Analyse von Fahrverhalten kann auf operationeller, taktischer oder strategischer Ebene geschehen, siehe auch Abschnitt 2.1. Die Ausgabe auf operationeller Ebene wären Kontrollaktionen der Fahrer (z. B. Lenkbewegungen oder Pedalstellungen). Auf taktischer Ebene kann eine Manövererkennung stattfinden (z. B. Abbiegen, Fahrstreifenwechsel, Halten), die strategische Ebene beschäftigt sich mit Plänen und Zielen. Das Ergebnis der Untersuchungen kann aber auch direkt der Zustand des Fahrers sein, z. B. um herauszufinden, wann der Fahrer müde wird.

Zielobjekt

Die Frage, ob das Verhalten des Fahrers des eigenen Fahrzeugs oder durch Umfeldsensorik erkannter Fahrzeuge analysiert werden soll, bestimmt wesentlich die Art und Qualität der verfügbaren Eingänge.

Eingänge

Eine wichtige Kenngröße sind die genutzten Signale. Typischerweise werden unterschiedliche Kombinationen folgender Eingänge verwendet: Lenk-/ Pedalbewegungen, Stellungen der Fahrtrichtungsanzeiger, Blickrichtung aus einer den Fahrer beobachtenden Kamera, Fahrzeugumfeldererkennung aus Kameras und/oder Radar-/Lidar-Sensorik, Kontext aus digitalen Karten oder Fahrstreifenerkennungssystemen, Fahrzeug-Fahrzeug- bzw. Fahrzeug-Infrastruktur-Kommunikation.

Methoden

Bei den veröffentlichten Ansätzen zur Fahrverhaltenserkennung dominieren bayessche Netze bzw. deren Erweiterungen. Andere Ansätze sind Support Vector Machines sowie Hidden-Markov- und kognitive Modelle¹.

Datenbasis

Grundsätzlich besteht die Möglichkeit, die Datensammlung in realem Verkehr oder in einem Simulator vorzunehmen. Ist man an Fahrmanövern interessiert, gibt es außerdem die wichtige Unterscheidung, ob die Probanden angeleitet wurden, ein Manöver zu fahren, oder ob „natürliches“, unbeeinflusstes Fahrver-

¹Unter einem kognitiven Modell wird in diesem Zusammenhang die maschinelle Modellierung der Kognitionsleistung eines Menschen verstanden.

halten erlaubt wurde.

Erkennungszeitpunkt

Je nach Ziel der Analyse ist entweder die möglichst frühzeitige Erkennung des Beginns eines Ereignisses von Interesse oder die nachträgliche Erkennung eines abgeschlossenen Ereignisses.

Detektionsumfang

Ein weiteres Kriterium ist die Unterscheidung, ob verschiedene Klassen in einem Mehrklassenproblem unterschieden werden sollen oder ein einzelnes, genau definiertes Ereignis vom Rest getrennt werden soll.

Kusano und Gabler untersuchen den Nutzen von Assistenzsystemen, speziell im Hinblick auf das Fahrverhalten [KG12]. Anders als bei vielen Betrachtungen von Unfallstatistiken liegt der Schwerpunkt auf dem Fehlverhalten des Fahrers, das ursächlich zu dem Unfall geführt hat. Durch Auswertung der „National Motor Vehicle Crash Causation Survey“ [BP08], einer speziellen Datenbank, die sich nicht auf Auswirkungen und Verletzungen bei Unfällen konzentriert, sondern auf die Arten des menschlichen Versagens, wird das Potential von Assistenzsystemen abgeschätzt. Dabei wird davon ausgegangen, dass eine Warnung nur bei bestimmten dominanten Unfallursachen hilft (wie beispielsweise bei einem abgelenkten Fahrer). Für ein radarbasiertes Warnsystem bei Auffahrunfällen und eine kamerabasierte Fahrstreifenverlassenswarnung werden Effektivitäten von Warnstufen abgeschätzt. Kusano und Gabler argumentieren, dass ohne Betrachtung des Fahrverhaltens bei Unfällen die Wirksamkeit von Assistenzsystemen tendentiell überschätzt wird.

Buld et. al. betrachten den Bedarf für Fahrerassistenzsysteme aus verkehrspsychologischer Sicht [BHK06]. In diesem Zusammenhang wurden im Fahrsimulator Probandenversuche von Auffahrten auf Autobahnen durchgeführt. Dabei hat sich herausgestellt, dass subjektive Fahrfehlereinschätzung und objektive Kriterien (wie Abstände oder Zeitlücken) in keinem signifikanten Zusammenhang stehen. Die Arbeit mündet in Hinweisen zur Gestaltung von Mensch-Maschine-Schnittstellen.

Das Thema „Mensch-Maschine-Schnittstelle“ ist für sich betrachtet ein großes Forschungsgebiet, das von einem besseren Verständnis des Fahrers, seiner aktuellen Belastung und seines mentalen Zustandes profitiert. Vorherrschend sind Fragen, wann [YYFK03] und wie [FM05] Assistenzsysteme warnen sollten.

Eine gute Kenntnis darüber, wie Fahrer bestimmte Aktionen ausführen, ist ebenfalls hilfreich bei der Auslegung teilautomatisierter Manöver, um eine hohe Kundenakzeptanz zu erreichen. Rano et. al. untersuchen beispielsweise das Verhalten von menschlichen Fahrern beim Spurhalten innerhalb eines Fahrstreifens, um den Regler

für einen automatisierten Fahrstreifenhalteassistenten diese Bewegungen möglichst gut imitieren zu lassen [RES13]. Das System soll sich dadurch natürlicher anfühlen. Wegscheider und Prokop ziehen aus simulativen Fahrermodellen Rückschlüsse über das zu erwartende Komfortempfinden von Assistenzsystemen [WP05].

Selbst im verwandten Forschungsbereich des autonomen Fahrens [LAB⁺11] wird menschliches Fahrverhalten immer mehr zum Thema. So argumentieren beispielsweise Agamennon et. al. in [ANN11], dass es für ein autonom agierendes Fahrzeug notwendig ist, das Verhalten der umgebenden menschlichen Fahrer antizipieren zu können, um sich sicher in diesem Umfeld bewegen zu können. Der Schwerpunkt liegt dementsprechend in der Abbildung von Interaktionen zwischen Fahrzeugen.

Fahrverhaltensuntersuchungen können darüber hinaus dem Zweck dienen, das Können von Fahrern zu evaluieren, um Fahrtrainings zu verbessern. Osguei und Choi bilden das Fahrverhalten von Probanden und eines professionellen Fahrers in einem Simulator mit Hilfe von Hidden-Markov-Modellen ab [OC12]. Im Anschluss nutzen sie ein Abstandsmaß zwischen je einem Probandenmodell und dem Modell für den professionellen Fahrer, um das Fahrkönnen des Probanden einzuordnen. Die objektive Auswertung über Hidden-Markov-Modelle kam dabei zu ähnlichen Ergebnissen wie die subjektive Einschätzung eines Experten.

Ein weiterer Einsatzzweck besteht in der Entwicklung von Systemen zur Erziehung des Fahrers. Aliane et. al. entwickeln ein System, um dem Fahrer nach Nutzung des Fahrzeugs seine Verkehrsverstöße aufzuzeigen [AFBM12]. Basierend auf einer Verkehrszeichenerkennung werden während der Fahrt verschiedene Verstöße wie überhöhte Geschwindigkeit oder Verletzung von Vorfahrtsregeln detektiert und dem Fahrer im Anschluss in gesammelter und komprimierter Form präsentiert.

Nicht nur die Modellierung des Fahrers im Assistenzsystem als Teil der Funktion, sondern auch die Untersuchung der potentiellen Änderung des Fahrverhaltens als Reaktion auf ein verbautes Assistenzsystem ist ein Aspekt, der bei der Entwicklung von Assistenzsystemen berücksichtigt wird. So untersuchen Freyer und Maurer die Änderung von Fahrstreifenwechselhäufigkeit, Ausscherverhalten und Wahl des Fahrstreifens als Reaktion auf die Gewöhnung an Abstandsregeltempomaten (ACC, engl. Adaptive Cruise Control) [FM06]. Dabei konnte anhand von Sensordaten und Fragebögen eine signifikante Änderung des Fahrverhaltens nachgewiesen werden. Als Fazit ziehen Freyer und Maurer, dass das Gesamtbild des Assistenzsystems stimmig sein muss, damit es vom Fahrer akzeptiert wird. Mayser argumentiert, dass durch Adaption der Systeme an die Erwartungen der Nutzer eine Steigerung der Kundenakzeptanz möglich ist [May04]. Dazu werden Fahrertypen aus Geschwindigkeits- und Beschleunigungsprofilen ermittelt, mit denen die Systeme nachparametriert werden sollen.

Braess und Donges betrachten die „Konsumierbarkeit“ von Assistenzsystemen, also die Gefahr, eine höhere Sicherheit durch Assistenzsysteme durch eine riskantere Fahrweise auszugleichen [BD06]. Ihrer Einschätzung nach besteht eine gute Chance, dass Sicherheitsgewinne durch moderne Fahrerassistenzsysteme nicht konsumiert werden, sofern sie korrekt ausgelegt und mit einer guten Mensch-Maschine-Schnittstelle versehen sind. Eine gegensätzliche Fragestellung, nämlich wie Fahrer auf technische Fehler des Fahrzeugs reagieren, untersuchen Neukum und Krüger am Beispiel von Störungen einer elektronischen Aktivlenkung [NK03]. Die Fähigkeit, nach Fehlverhalten eines technischen Systems die Kontrolle zu behalten oder wiederzuerlangen, hat Einfluss auf die Klassifikation der Sicherheitsrelevanz des technischen Systems.

Fahrerzustandsanalysen beschäftigen sich mit der Fragestellung, ob ein Fahrer aktuell aufmerksam und leistungsfähig ist oder ob seine Leistungsfähigkeit beispielsweise durch Müdigkeit oder Ablenkung eingeschränkt ist. Eingänge in solche Systeme sind oftmals Analysen der Augenbewegungen [AM13; MG13], teilweise erweitert um andere situative und physiologische Größen wie Sprache, Gesten, Herzschlag oder Hautspannung [TYJ⁺13]. Alternativ kann diese Untersuchung auf dem dynamischen Zustand des Fahrzeugs, gemessen durch Längs- und Querschleunigung, basieren [KS12]. Einen anderen Ansatz verfolgen Eren et. al. [EMAY12]: Mit Hilfe der Sensorik eines Smartphones kann auf Position, Geschwindigkeit, Beschleunigung und Gierwinkel des Fahrers geschlossen werden. Anhand dieser Signale wird eine binäre bayessche Klassifikation zwischen „sicher“ und „riskant“ vorgenommen. Besondere Vorkommnisse werden dabei vor allem durch hohe Gradienten in den Beschleunigungssignalen detektiert. Als Vorteile eines auf Smartphones basierenden Systems werden angeführt, dass solche Systeme günstig sind, da keine extra Sensorik notwendig ist, sowie dass das Smartphone an die Person gebunden und damit portabel zwischen Fahrzeugen ist. Der Kostenaspekt ist sicherlich ein Vorteil gegenüber Fahrerbeobachtungskameras, allerdings stehen Beschleunigungssignale und andere Informationen über die Fahrzeugdynamik auch heute schon für andere Anwendungen im Fahrzeug bereit und sind deshalb ebenfalls nicht mit zusätzlichen Kosten verbunden. Bezüglich Portabilität haben sowohl das Binden eines Assistenzsystems an das Fahrzeug als auch an die Person Vor- und Nachteile, so dass es keinen eindeutigen Vorzug gibt.

Auch ein prinzipiell aufmerksamer Fahrer kann andere Verkehrsteilnehmer übersehen. Insbesondere das Übersehen von Fußgängern kann zu gefährlichen Situationen führen. Engel und Curio lenken ihre Aufmerksamkeit deshalb nicht auf den Fahrer, sondern auf den Fußgänger, und stellen die Frage, mit welcher Wahrscheinlichkeit ein Fußgänger vom Fahrer gesehen wurde [EC11]. Diese Frage wird über ein Modell der Wahrnehmung des Fahrers sowie maschinellem Sehen mit einer Kamera beantwortet.

Eine ähnliche Zielstellung verfolgen Fukagawa und Yamada [FY13] - allerdings nehmen sie das Fahrzeug mit in den Regelkreis. Die Aufmerksamkeit des Fahrers wird unter der Arbeitshypothese, dass Fahrer ihr Verhalten verändern, wenn sie

einen potentiell durch sie gefährdeten Fußgänger gesehen haben, evaluiert. Als Eingänge dienen in diesem Fall Pedale, Lenkwinkel, die Fahrdynamik sowie in der Umgebung befindliche Fahrzeuge und das Fahrumfeld allgemein (Anzahl der Fahrstreifen, Steigung der Straße, ...). Methodisch erfolgt die Auswertung mit Hilfe eines Regelwerks und bayesscher Inferenz.

Die Frage, ob ein Objekt vom Fahrer gesehen wurde, stellt sich auch bei Übergabesituationen zwischen Assistenzsystem und Fahrer. Wenn potentiell gefährdende Objekte bei einer Übergabe nicht gesehen wurden, kann sich eine kritische Situation ergeben, der z. B. durch gezielte Aufmerksamkeitssteuerung entgegengewirkt werden müsste. Bär et. al. untersuchen Übergabeszenarien eines Umfelderkennungssystems bestehend aus Laserscanner, Kamera und Fahrzeugbus. Zusätzlich wird die Blickrichtung des Fahrers über eine Fahrerbeobachtungskamera erfasst und die Konfidenz, dass der Fahrer ein von der Umfeldsensorik erkanntes Objekt ebenfalls gesehen hat, ausgewertet [BLNZ13]. Bei potentiell übersehenen Objekten wird eine Einstufung der Gefährlichkeit vorgenommen, die auf räumlichen Kriterien basiert.

Anders herum hat natürlich auch das eigene Fahrzeug Einfluss auf die Umgebung. Bando et. al. untersuchen, in wie weit Fahrerassistenzsysteme nicht nur zur Verbesserung der Verkehrssicherheit, sondern auch des Verkehrsflusses eingesetzt werden können [BMT11]. Dazu wird die Existenz von Interaktionen zwischen Fahrzeugen mit einem bayesschen Ansatz geschätzt und eine mikroskopische² Verkehrssimulation aufgebaut. Simuliert werden normale Fahrer, sich inkonsistent verhaltende Fahrer (beispielsweise durch zufälliges Bremsen) und Fahrzeuge, die mit ihrem System ausgerüstet sind. In den Simulationen konnte das System einen deutlich flüssiger laufenden Verkehr erreichen.

Der Wunsch nach realistischen mikroskopischen Simulatoren, die die Reaktionen von Umgebungsverkehr abbilden, ist ein häufiger Motivator für das Erstellen von Fahrermodellen [Ehm01; LW99]. Man verspricht sich dadurch unter anderem, Assistenzsysteme schon früh in der Entwicklungsphase bewerten zu können. Fahrverhaltensanalysen zur Modellbildung sind für diverse Fahrmanöver durchgeführt worden, z. B. für Fahrstreifenwechsel [Hen10; ZQL⁺14], Überholvorgänge [PH04] oder Anfahrten an Ampelkreuzungen [MTBT02].

Die Erkennung von Fahrweisen und abgeschlossenen Manövern ist nicht nur für die Modellbildung in Simulatoren und andere nachträgliche Verwendungen nützlich, sondern auch online zum Adaptieren von Assistenzsystemen auf den Fahrer. Bando et. al. extrahieren sogenannte „Fahr-Themen“ (drive topics) automatisch aus aufgenommenen Daten [BTNT13]. Unter Verwendung von Hidden-Markov-Modellen werden

² *Mikroskopisch* bedeutet im Zusammenhang mit Verkehrssimulatoren, dass einzelne Fahrzeuge simuliert werden. *Makroskopische* Simulationen arbeiten auf einem höheren Abstraktionsniveau, z. B. auf der Basis von Verkehrsdichten und Durchschnittsgeschwindigkeiten.

die interessierenden Bereiche aus dem Datenstrom, bestehend aus Geschwindigkeit und Pedalbewegungen, segmentiert und hinsichtlich ihrer Auftretensverteilungen in Cluster zusammengefasst. Schließlich werden die Cluster mit natürlicher Sprache beschrieben (z. B. „Phase mittlerer Geschwindigkeit und hoher Beschleunigung“). Das Ziel der Untersuchung ist, Fahrverhalten allgemein besser zu verstehen, um so in Zukunft besser mit dem Fahrer interagieren zu können. Yao et. al. führen ihre Fahrstreifenwechseluntersuchungen vor allem mit dem Ziel durch, eine nachgeschaltete Trajektorienplanung verbessern zu können [YZBZ13; YZDZ12].

Einige Forschungsgruppen arbeiten an der Vorhersage von Fahrerreaktionen auf operationeller Ebene. Angkitrakul et. al. beschäftigen sich mit der Vorhersage von Pedalbewegungen von Fahrern bei Folgefahrten als Reaktion auf die Fahrzeuggeschwindigkeit und den Abstand zum vorderen Fahrzeug [AMT11]. Methodisch angesetzt wird mit Gaussian-Mixture-Modellen kombiniert mit einer maximum a-posteriori online Parameterschätzung. In weitergehenden Arbeiten wurde das Framework auf individuelle Modelle für jeden Fahrer erweitert [AMT12]. Für bislang unbekannte Fahrer wird weiterhin ein allgemeingültiges Modell vorgehalten. Taniguchi et. al. sagen zusätzlich zu Pedalbewegungen auch Lenkbewegungen voraus [TNH⁺12]. Der methodische Ansatz sind an Systeme zur Spracherkennung angelehnte hierarchische Markov-Modelle.

Butakov et. al. schätzen anstehende Längsbeschleunigungen bei Folgefahrten unter Verwendung von Gaussian-Mixture-Modellen [BITC12]. Als Eingänge dienen dynamische Größen des eigenen und des vorausfahrenden Fahrzeugs. Die prädizierten Beschleunigungen werden in der Folge für eine Fahrverhaltensklassifikation genutzt. So wird angenommen, dass normales Fahrverhalten vorliegt, wenn prädizierter und aktueller Wert in gewissem Rahmen übereinstimmen. Das Ziel der Arbeit ist, einerseits Abweichungen von normalem Fahrverhalten zu erkennen, andererseits Assistenzsysteme online je nach Fahrer nachparametrieren zu können.

Auch im Bereich der frühzeitigen Erkennung von anstehenden Fahrermanövern auf taktischer Ebene gibt es diverse Forschungsarbeiten [DT11], deren Erkennungszeitpunkte mangels Referenz für die mentale Entscheidungsfindung des Fahrers leider nicht untereinander vergleichbar sind.

Ein Schwerpunkt in diesem Bereich ist die Erkennung einer klar festgelegten Fahrsituation. Dagli beschäftigt sich mit der Erkennung von Einscherern zur Verbesserung eines Abstandsregeltempomaten [DR02]. Dabei wird ein Wahrscheinlichkeitsbaum aller an der Situation beteiligten Fahrzeuge erstellt und mit dynamischen bayesschen Netzen ausgewertet. In nachfolgenden Arbeiten ist dieser Ansatz immer weiter aufgeweitet worden, u.a. durch Berücksichtigung von immer mehr Eingangssignalen (Geschwindigkeit, Beschleunigung und Lateralgeschwindigkeit des Fremdfahrzeugs, Distanz zwischen Eigen- und Fremdfahrzeug, Netto-Zeitlücke, Zeit bis zur Kollision)

[Dag05; DBB02; DBS03; DBSS04].

Andere Systeme haben den Anspruch, ein globaleres Verständnis der aktuellen Verkehrssituation zu entwickeln. Bei der Erkennung der taktischen Manöver kommen Expertensysteme und Regelwerke in unterschiedlichen Ausprägungen zur Anwendung [HDT⁺10; KWD⁺11; LGTH05; MLVH04; PD02]. Nagel skizziert ein von der Straßenverkehrsordnung deduktiv abgeleitetes Regelwerk für Autobahnscenarien [NA03; Nag06]. Arens et. al. verfolgen einen analogen Ansatz für videoüberwachte städtische Kreuzungen [AON04]. Ebenfalls basierend auf Verkehrsüberwachungskameras werten Varadarajan et. al. Beziehungen zwischen Fahrern mit neurobiologischen Modellen aus [VZV11]. Sowohl Habenicht [HWB⁺11] als auch Rössler [RFL06] setzen mit Regeln basierend auf Fuzzy-Logik an.

Salvucci baut ein kognitives Modell als Verhaltensmodell für diskrete Manöver auf [SBL01; SMKY07]. Inspiriert von kognitiven Tutorensystemen besteht das System aus einer Wissensrepräsentation und einer Leistungsevaluierung. Die Wissensbasis wurde in einem Fahrsimulator eingefahren, als Signale dienen neben der Fahrzeugdynamik u.a. auch die Präsenz und Distanz zu anderen Fahrzeugen. Zum klassischen Aufbau eines Expertensystems fehlt noch eine lernende Komponente, die in Salvuccis System noch nicht vorhanden ist.

Die lernende Komponente rücken Graf et. al. in den Vordergrund [GDFD13]. Für Einschererszenarien auf Autobahnen wird die Wissensbasis während Testfahrten in realem Verkehr beständig vergrößert. Dabei wird umgebender Verkehr mit einem radarbasierten Tracking verfolgt. Außerdem werden Fahrstreifen mit einer Kamera erkannt. Für sich so ergebende Situationen werden Features extrahiert und mit ähnlichen Fällen aus dem Gedächtnis des Systems verglichen. Dann wird eine Lösung erzeugt, die im Nachgang analysiert wird. Das Analyseergebnis wird dem Gedächtnis hinzugefügt, um sowohl richtige Entscheidungen bestätigen als auch aus falschen Entscheidungen lernen zu können.

Auch bei Lefèvre et. al. nimmt der über Umfeldsensorik erfasste Kontext einen dominanten Stellenwert ein [LLI11]. Lefèvre konzentriert sich auf Manövererkennung in Kreuzungsszenarien. Der Begriff des „Manövers“ ist dabei definiert als der Fahrstreifen, auf dem die Kreuzung verlassen wurde. Ein Manöver wurde also richtig erkannt, wenn der richtige Fahrstreifen erkannt wurde. Als Eingänge dienen eine sehr feine Modellierung der Kreuzung sowie über laserscannerbasiertes Tracking erkannte Objekte. Der Ansatz stützt sich primär auf geometrische Zuordnungen von Objekten auf der Karte, die mit bayesschen Netzen ausgewertet werden. Kinematische Größen werden nicht verwendet. Im Anschluss erfolgt eine Risikobewertung der Kreuzungssituation [LLI12]. Dafür wird als weitere Informationsquelle Fahrzeug-Fahrzeug-Kommunikation eingeführt. Für jedes Fahrzeug in der Szene wird eine Manöverintention geschätzt sowie die Trajektorie auf dem Manöverpfad verfolgt.

Als Maß für das Risiko der Szene wird die Wahrscheinlichkeit, dass die Erwartung an ein Fahrzeug und die Intention des zugehörigen Fahrers nicht zusammenpassen, eingeführt und mit Partikelfiltern ausgewertet.

Ebenfalls auf Kreuzungsszenarien konzentrieren sich Liebner et. al. [LBKS12]. Abbiege- und Anhaltemanöver sollen aus dem Geschwindigkeitsprofil erkannt werden. Dabei werden Geschwindigkeitsprofile für bestimmte Kreuzungsszenarien als Referenz vermessen. Da Geschwindigkeitsprofile bei Folgefahrten nicht mit freier Fahrt vergleichbar sind, wird dieser Referenz ein Folgefahrtmodell aus einem mikroskopischen Simulator überlagert. Die Auswertung erfolgt auch in diesem Fall mit bayesschen Netzen.

In der Folge entfernt sich Liebner sich von dem Ansatz, diskrete Manöver zu erkennen und prädiziert stattdessen Trajektorien-Hypothesen [LRKS13]. Die erwähnten, für bestimmte Kreuzungen aufgenommenen Geschwindigkeitsprofile werden zu durchschnittlichen Trajektorien integriert. Ausgehend von einer hochgenauen Lokalisierung von Objekten auf diesen Trajektorien wird ein Hypothesenbaum bezüglich Weiterfahrt oder Fahrstreifenwechsel aufgebaut. Aus dem Geschwindigkeitsprofil, dem Signal des Fahrtrichtungsanzeigers und der Blickrichtung des Fahrers wird die weitere Trajektorie inferiert. Dabei wird explizit die Hypothese berücksichtigt, dass das Signal des Fahrtrichtungsanzeigers fehlerhaft ist.

Fahrer bereiten anstehende Manöver vor, bevor das Manöver in der Fahrdynamik sichtbar wird, beispielsweise durch Blicke über die Schulter, in Spiegel oder in bestimmte Richtungen. Die frühesten Anzeichen über ein anstehendes Manöver sind deshalb aus Fahrerbeobachtungskameras zu erwarten. Diese Funktionalität ist noch kein Standard in Personenkraftwagen und damit mit zusätzlichem Aufwand und Kosten verbunden. Auch die Fahrerakzeptanz von diesen Systemen ist noch nicht geklärt.

Wenn diese Nachteile allerdings in Kauf genommen werden, kann eine frühzeitige Manövererkennung erreicht werden. Morris et. al. erkennen Fahrstreifenwechsel basierend auf einem Kopf-Tracking-System für den Fahrer sowie mehreren Radarsensoren und einer Kamera für Fahrstreifenverlassenswarnungen [MDT11]. Als Klassifikator wird eine Support Vector Machine eingesetzt. Morris trägt dabei dem Phänomen, dass wertvolle Information für Fahrstreifenwechsel nicht in einem einzelnen Featuresatz, sondern im Zeitverlauf von Features enthalten ist, Rechnung, indem er den Featurevektor über einen Sliding-Window-Ansatz auf etwa 500 Dimensionen aufweitet. McCall und Trivedi nutzen zusätzlich zur Kopfkamera noch eine Fußkamera zur Manövererkennung, um anstehende Pedalbewegungen ebenfalls frühzeitig erfassen zu können [MT06].

Auch ohne Beobachtung des Fahrers durch zusätzliche Sensorik ist eine Erkennung

in frühen Manöverphasen möglich. Bi et. al. vergleichen Sequenzen von Lenkwinkel und Längsgeschwindigkeit in einem Zeitfenster mit simulierten Signalen aus vordefinierten Modellen [BYW13]. Der Vergleich basiert auf einer Auswertung der mittleren quadratischen Abweichung. Kumar et. al. stützen sich zur Erkennung von Fahrstreifenwechseln auf die laterale Position im Fahrstreifen, Lenkwinkel sowie deren Ableitungen [KPLL13]. Die Inferenz erfolgt auch in diesem Fall über eine Support Vector Machine mit aufgeweitetem Featurevektor.

Pentland und Liu nutzen zur Manövererkennung Hidden-Markov-Modelle, die über Viterbi-Dekodierung ausgewertet werden [LP97; PL99]. Als Eingänge dienen Signale aus Probandenversuchen in einem Fahr Simulator, denen Kommandos gegeben wurden, bestimmte Manöver zu beginnen. Kuge erweitert das System um Notfall-Fahrstreifenwechsel, die ebenfalls im Simulator durchgeführt wurden [KYSL00]. Als Schlussfolgerung wird gezogen, dass Notfall-Wechsel gut erkannt werden können, die Unterscheidung zwischen Fahrstreifenfolgeverhalten und normalen Fahrstreifenwechseln jedoch schwierig ist und zusätzlichen Kontext benötigt.

Im weiteren Verlauf dieses Kapitels wird ein System zur frühzeitigen Erkennung von Fahrmanövern des eigenen Fahrzeugs auf taktischer Ebene vorgestellt. Eine frühe Erkennung eines anstehenden Manövers wird definiert als erkannte *Fahrerabsicht*.

Im Vergleich zum Stand der Technik ist die Arbeit thematisch und methodisch verwandt mit den Arbeiten von Liu und Pentland. Wie schon Liu und Pentland werden auch in dieser Arbeit Hidden-Markov-Modelle als der am Besten geeignete methodische Rahmen für taktische Manövererkennung angesehen. Die Gründe für diese Ansicht werden im folgenden Abschnitt genauer erläutert.

Im Gegensatz zum Vorgehen bei Liu und Pentland wird in der vorliegenden Arbeit nicht auf simulierte Daten zurückgegriffen, sondern auf Testfahrten in realem Straßenverkehr, was einen Unterschied in Güte und Verfügbarkeit von Signalen macht und entsprechend methodisch berücksichtigt werden muss. Die Modellierung der Markov-Ketten wird nicht durch Expertenwissen vorgegeben, sondern ergibt sich bei dem gewählten Ansatz durch automatische Segmentierung während des Trainings implizit, wodurch eine frühere Erkennung ermöglicht wird. Die zu erkennenden Manöver werden um Abbiegemanöver erweitert. Im Gegensatz zu Pentland und Liu werden bei Testfahrten die zu fahrenden Manöver nicht vorgegeben, sondern auf natürliches Fahrverhalten ohne Kenntnis des Zwecks der Testfahrt gesetzt. Eigene Voruntersuchungen deuten darauf hin, dass in diesem Fall Manöver verwaschener ausgeführt werden, was eine Klassifikation erschwert. Trotz dieser Erschwernisse kann das System bessere Klassifikationsleistungen erzielen, was durch neuartige Ansätze bei der Markov-Modellierung und der Inferenz ermöglicht wird.

Es soll zunächst motiviert werden, warum Hidden-Markov-Modelle (HMMs) eine

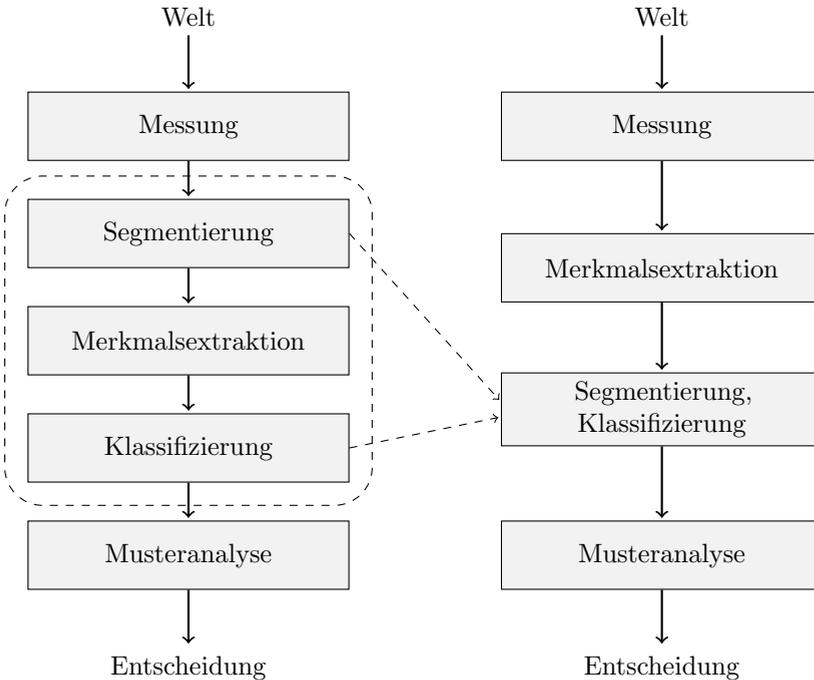


Abbildung 3.1: Links: Klassischer Aufbau eines Mustererkennungssystems. Rechts: Integrierte Lösung des Segmentierungs- und Klassifikationsproblems bei HMMs.

geeignete Methode zur Erkennung von Fahrmanövern darstellen. Daran schließt sich ein kompakter Überblick über die Theorie der Mustererkennung mit Hidden-Markov-Modellen an.

3.2 Motivation der Methodik

Die maschinelle *Mustererkennung* beschäftigt sich mit der Nachbildung der menschlichen Wahrnehmung durch Maschinen. Der typische Aufbau eines Mustererkennungssystems ist auf der linken Seite in Abb. 3.1 dargestellt [DHS00]. Sensoren beobachten die Welt und liefern Daten, die interessierende Objekte beinhalten können. In einem Segmentierungsschritt werden die Daten so aufbereitet, dass einerseits die Daten für ein einzelnes Objekt zusammengefasst, andererseits die interessierenden Objekte

möglichst voneinander getrennt werden. Dieser Schritt ist sensorabhängig und oft setzt oft tiefes Wissen über die Problemstellung voraus. Bei der Bildverarbeitung kann dies z. B. durch eine Ausblendung des Hintergrundes und Trennung der verbleibenden Bereiche geschehen, bei der Laserscannerdatenverarbeitung werden oft Punktwolken anhand eines Abstandskriteriums zusammengefasst. Aus den Rohdaten oder den Segmenten werden dann Merkmale extrahiert, die einem Klassifikator zugeführt werden. Das Ergebnis des Klassifikators sind erkannte und diskreten Klassen zugeordnete Objekte, die dann in einer Musteranalyse näher untersucht werden können, um z. B. Beziehungen zwischen Objekten aufzudecken und schlussendlich zu einer Entscheidung zu kommen.

Dieser Ansatz ist vor allem dann problematisch, wenn der Schritt der Segmentierung nicht unabhängig von der Klassifizierung gelöst werden kann, wenn also für die Segmentierung schon ein semantischer Kontext benötigt wird, der eigentlich erst durch die Klassifizierung erzeugt wird.

Diesem Problem begegnen Hidden-Markov-Modelle, indem die Schritte der Segmentierung und der Klassifizierung integriert gelöst werden, Abb. 3.1 rechts. Dem Klassifikator wird ein Merkmalsstrom zur Verfügung gestellt, bei dessen Auswertung nicht nur ausgegeben wird, wie gut die Daten insgesamt auf das Modell passen, sondern auch, welche Teile der Daten auf welche Teile im Modell besonders gut passen. Eine ähnliche Leistungsfähigkeit ergibt sich bereits beim Training des Klassifikators, wo automatisch Segmente in den Daten identifiziert und Segmenten im Modell zugeordnet werden.³

Die methodische Entwicklung von HMMs wurde in der Vergangenheit vor allen von Domänen vorangetrieben, in denen die Eigenschaft der automatischen Segmentierung notwendig ist. Insbesondere die Forschergemeinschaft für automatische Spracherkennung hat sich hier hervorgetan, die vor dem Problem steht, dass in einem Redefluss die einzelnen Wörter nicht getrennt werden können, ohne den Wortschwall selbst zu verstehen (z. B. [MHG06]). Andere traditionelle Anwendungsgebiete sind die Handschrifterkennung⁴ oder die DNS-Sequenzierung in der biologischen Forschung. Bei der DNS-Sequenzierung geht es vor allem darum, aktive Gene in langen, größtenteils inaktivem genetischen Material zu identifizieren. In diesem Fall tritt also nicht die Klassifikation, sondern die Lokalisierung und damit die Segmentierung selbst als Ergebnis in den Vordergrund.

Bei der Manövererkennung steht man ebenfalls vor der Herausforderung, die Manöver integriert sowohl in einem kontinuierlichen Strom von Sensorsignalen zu lokalisieren

³Aufgrund der Eigenschaft der automatischen Segmentierung werden HMMs manchmal irreführend auch als *segmentierungsfrei* bezeichnet.

⁴Im Gegensatz dazu lassen sich bei maschineller Schrift bei vielen Schriftarten die Zeichen ohne semantisches Verständnis voneinander trennen.

als auch zu klassifizieren.

HMMs haben jedoch noch andere signifikante Stärken im Kontext der Manövererkennung. Bei Hidden-Markov-Modellen wird nicht ein einzelner, aktueller Merkmalsvektor klassifiziert, sondern immer zeitlich gepufferte Signalverläufe von Merkmalen. Da angenommen wird, dass Manöver nicht durch einen einzelnen Zustand, sondern durch Veränderungen im Verhalten der Fahrer maßgeblich bestimmt werden, stellt diese Eigenschaft einen entscheidenden methodisch inhärenten Vorteil dar. Bei Klassifikationsmethoden, die auf einzelnen Merkmalsätzen arbeiten, muss der Merkmalsvektor um Merkmalswerte aus der Vergangenheit aufgestockt werden oder es müssen Merkmale konstruiert werden, die die Vergangenheit beinhalten⁵, um eine ähnliche Wirkung zu erhalten. Dadurch wird jedoch die Dimension des Merkmalsraumes erhöht, was im Bereich des maschinellen Lernens schnell im *Fluch der Dimensionalität*⁶ münden kann, durch den ein Training deutlich erschwert wird. Ein zusätzlicher angenehmer Nebeneffekt der Klassifizierung auf gepufferten Zeitfenstern ist die einfache Behandlung von Messungen aus unterschiedlichen Quellen und mit verschiedenen Messfrequenzen. Die Frequenzangleichung in einem Zeitfenster kann durch einfache Interpolation erfolgen. Ebenso sind für Messungen mit unterschiedlicher Totzeit keine aufwändigen „out-of-sequence“ Verfahren notwendig – die Daten können direkt an die richtige Stelle im Zeitfenster einsortiert werden. Die Qualität von aus Messungen berechneten Merkmalen, wie z. B. zeitliche Ableitungen gemessener Größen, profitiert ebenfalls davon, dass ein Zeitfenster als Ganzes anstatt nur ein aktueller Wert betrachtet wird.

Zwei weitere im automotiven Kontext bedeutende Eigenschaften von HMMs werden in den folgenden Kapiteln noch deutlich werden: Zum einen ist die Mustererkennung mit diesen Modellen äußerst recheneffizient umsetzbar. Zum anderen agieren die Modelle nicht als „black-box“, sondern ermöglichen es, sowohl trainierte Modelle selbst als auch das Zustandekommen der Segmentierungs- und Klassifikationsergebnisse in der Anwendung dieser Modelle zu analysieren.

Die folgenden Abschnitte geben eine Einführung in die theoretischen Grundlagen der Mustererkennung mit Markov-Modellen. Eine Kurzeinführung in die Grundbegriffe der Stochastik und die in dieser Arbeit verwendete Notation ist in Anhang B zu finden.

⁵Bei der Objektklassifikation kann das z. B. die Information sein, wie lange ein Objekt insgesamt gesehen wurde oder die zurückgelegte Wegstrecke aus einem vorgelagerten Verfahren zur Objektverfolgung.

⁶Der Begriff wurde von Richard Bellman, US-amerikanischer Mathematiker und Entdecker der Dynamischen Programmierung, geprägt [Bel57].

3.3 Grundlagen der Mustererkennung mit Hidden-Markov-Modellen

Empfehlenswerte Artikel zum Umgang mit HMMs sind die Schriften von Rabiner [Rab89; RJ86]. Eine sehr umfassende, wenn auch speziell auf die Sprachverarbeitung zugeschnittene Behandlung findet sich in [HAH01]. Für einige Erweiterungen von HMMs sowie eine nähere Betrachtung der Beziehungen von HMMs mit bayesschen Netzen siehe [Mur02a; Mur02b]. Die in dieser Arbeit verwendete Notation orientiert sich an der Habilitationsschrift von Fink [Fin03], welche ihrerseits auf den Artikeln von Rabiner basiert.

3.3.1 Stochastische Prozesse und Markov-Ketten

Betrachtet man die von Zufallsvariablen erzeugten Realisierungen über einen längeren Zeitraum hinweg, ergeben sich zufällige Variationen der Ergebnisse. Die wahrscheinlichkeitstheoretischen Gesetzmäßigkeiten beim Erzeugen dieser Realisierungen, wie Wahrscheinlichkeitsfunktion oder -dichte, bleiben jedoch erhalten.

Möchte man Veränderungen in den stochastischen Eigenschaften selbst mathematisch beschreiben, bedient man sich eines *stochastischen Prozesses*.

Anschaulich ist ein diskreter⁷ stochastischer Prozess eine Folge von diskreten Zufallsvariablen (S_1, S_2, \dots) . Jede dieser Zufallsvariablen kann Werte s_i nach einer individuell verschiedenen Verteilung annehmen. Bei diskreten stochastischen Prozessen ist es üblich, Werte s_i der Zufallsvariablen als Zustände und den stochastischen Prozess selbst als eine Zustandsfolge aufzufassen. Die Wahrscheinlichkeit, dass zum Zeitpunkt t der Zustand s_t angenommen wird, wird als $P(S_t = s_t)$, oder, wenn eindeutig, kurz als $P(s_t)$ bezeichnet.

Im Allgemeinen kann die Verteilungsfunktion zu einem Zeitpunkt explizit von der Zeit sowie allen vergangenen und zukünftigen Zuständen abhängen. Beim Übergang zu Markov-Ketten werden eine Reihe von Einschränkungen gemacht. Eine *Markov-Kette 1. Ordnung* ist ein stationärer kausaler gedächtnisloser stochastischer Prozess.

⁷Kontinuierliche stochastische Prozesse werden in dieser Arbeit nicht behandelt.

$$P(s_t \mid s_1, s_2, \dots, s_{t-2}, s_{t-1}, s_{t+1}, \dots, s_T, t) = P(s_t \mid s_{t-1}) \quad (3.1)$$

entfällt bei Gedächtnislosigkeit 
 entfällt bei Kausalität 
 entfällt bei Stationarität 

In Beziehung (3.1) werden die Einschränkungen aufgeschlüsselt. Bei einem *stationären* stochastischen Prozess fällt die explizite Zeitabhängigkeit der Zustandsfolge weg. Bei einem *kausalen* stochastischen Prozess hängt ein Wert der Zustandsfolge nur von seiner Vergangenheit ab, nicht jedoch von seiner Zukunft. Die *Markov-Eigenschaft* beschreibt ein begrenztes Gedächtnis, d.h. die Eigenschaften des Prozesses sind nur von einer begrenzten Anzahl vorangegangener Zustände abhängig. Wenn die Abhängigkeit sich nur auf den aktuellen Zustand beschränkt, spricht man von einer Markov-Kette erster Ordnung oder auch von Gedächtnislosigkeit. Dies ist keine so große Einschränkung, wie es vielleicht zunächst erscheinen mag, denn prinzipiell lässt sich der Einfluss vorangegangener Zustände durch eine Erweiterung des Zustandsraumes auch in einer Markov-Kette erster Ordnung modellieren.

Eine kompakte Beschreibung von Markov-Ketten kann über die *Zustandsübergangsmatrix* erfolgen. In Zeile i , Spalte j dieser Matrix steht die Wahrscheinlichkeit, im nächsten Zeitschritt in Zustand j zu wechseln unter der Voraussetzung, dass man sich momentan in Zustand i befindet.

$$\mathbf{A} = [a_{i,j}] = [P(S_t = s_j \mid S_{t-1} = s_i)] \quad (3.2)$$

Die Matrix \mathbf{A} ist eine *stochastische Matrix*: Sie ist quadratisch, enthält nur Einträge zwischen 0 und 1, und alle Zeilensummen ergeben sich zu 1.

Komplettiert wird die Beschreibung einer Markov-Kette durch die Angabe eines Vektors von Anfangswahrscheinlichkeiten

$$\pi = [\pi_i] = [P(S_1 = s_i)]. \quad (3.3)$$

3.3.2 Hidden-Markov-Modelle

Einem HMM liegt ein zweistufiger stochastischer Prozess zugrunde, siehe Abb. 3.2. Die erste Stufe wird von einer Markov-Kette gebildet. Allerdings ist diese Markov-

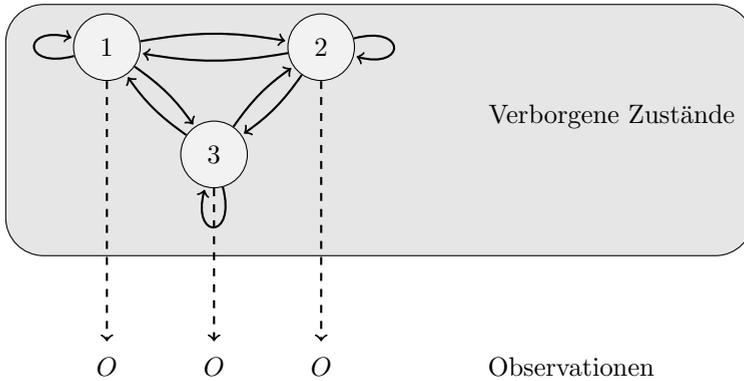


Abbildung 3.2: Hidden-Markov-Modell als zweistufiger Zufallsprozess. Die Zustände des Markov-Modells sind verborgen, nach außen sichtbar ist nur eine Folge von Observationen (O_1, O_2, \dots) .

Kette *verborgen* (engl. hidden), d.h. es kann von außen nicht erfasst werden, in welchem Zustand der Markov-Kette man sich gerade befindet.

In jedem Zeitschritt t erzeugt der aktuelle Zustand eine *Observation* O_t (auch Emission oder Beobachtung genannt) anhand einer zustandsspezifischen Verteilung. Bei einer Beobachtung des Modells über einen Zeitraum T ist nur diese Observationsfolge (O_1, O_2, \dots, O_T) sichtbar. Einzelne Beobachtungen können entweder aus einem diskreten Alphabet $o_1 \dots o_m$ kommen oder kontinuierliche Werte annehmen. Im ersten Fall erfolgt die Modellierung über eine zustandsspezifische Emissionswahrscheinlichkeit

$$b_j(o_k) = P(O_t = o_k | S_t = s_j) \quad (3.4)$$

während im zweiten Fall mit einer ebenfalls zustandsspezifischen Wahrscheinlichkeitsdichte

$$B_j(\mathbf{x}) = p(\mathbf{x} | S_t = s_j) \quad (3.5)$$

angesetzt wird. Je nach Art der Beobachtungen unterscheidet man zwischen diskreten und kontinuierlichen HMMs. Im Allgemeinen wird in jedem Zeitschritt ein Satz von Werten beobachtet, einzelne Beobachtungen O_t können also vektoriell sein.

Ein Hidden-Markov-Modell wird daher vollständig beschrieben durch die Parameter der zugrundeliegenden Markov-Kette und die zugehörigen Emissionsverteilungen. Zusammenfassend sind das

- die Zustandsübergangsmatrix \mathbf{A} , aus deren Dimension sich auch die Anzahl der Zustände ergibt,
- ein Vektor π mit Anfangswahrscheinlichkeiten der Zustände sowie
- zustandsspezifische Emissionsverteilungen b_j .

Im Folgenden wird die Gesamtheit der Modellparameter eines HMM mit λ bezeichnet.

Beim Umgang mit HMMs sind vor allem drei Fragestellungen bedeutend:

1. Das **Evaluierungsproblem**: Es seien eine Beobachtungsfolge $\mathbf{O} = (O_1, O_2, \dots)$ und ein Modell λ gegeben. Wie hoch ist die Wahrscheinlichkeit, dass diese Beobachtungsfolge von dem vorliegenden Modell erzeugt wurde?

Diese Fragestellung kann effizient mit dem Vorwärts-Algorithmus (Kapitel 3.3.3.1) oder einer Modifikation desselben (Kapitel 3.3.4) beantwortet werden.

2. Das **Dekodierungsproblem**: Es seien eine Beobachtungsfolge $\mathbf{O} = (O_1, O_2, \dots)$ und ein Modell λ gegeben. Vorausgesetzt, die Beobachtungsfolge wurde vom vorliegenden Modell erzeugt – wie war die wahrscheinlichste Abfolge der internen, verborgenen Zustände?

Der Viterbi-Algorithmus [Vit67] (Kapitel 3.3.5.2) ist eine geeignete Methode zur Lösung dieses Problems.

3. Das **Lernproblem**: Es seien eine oder mehrere Beobachtungsfolgen gegeben. Welches Modell erklärt diese Daten möglichst gut?

Ein verbreitetes Verfahren zur Bestimmung von Modellparametern ist der Baum-Welch-Algorithmus [BPSW70] (Kapitel 3.3.6).

In den folgenden Kapiteln werden an verschiedenen Stellen Wahrscheinlichkeiten betrachtet, beispielsweise in Form von Produktionswahrscheinlichkeiten, Vorwärts- bzw. Rückwärtsvariablen oder ähnlichen Konstrukten. Im Falle von diskreten HMMs sind dies in der Tat mathematisch korrekt definierte Wahrscheinlichkeiten. Für diesen, in der Notation einfacheren Fall werden auch die Lösungsalgorithmen zu den Problemstellungen von HMMs beschrieben. Die Erweiterung auf den praxisrelevanten kontinuierlichen Fall geschieht völlig analog. Allerdings ergeben sich dann keine Wahrscheinlichkeiten mehr, sondern Werte von Wahrscheinlichkeitsdichtefunktionen. Wie in der Literatur üblich wird in dieser Arbeit dennoch auch im kontinuierlichen Fall an dem Begriff der Wahrscheinlichkeit festgehalten.

3.3.3 Produktionswahrscheinlichkeit

Zur Lösung des Evaluierungsproblems wird die *Produktionswahrscheinlichkeit* $P(\mathbf{O} | \lambda)$ herangezogen. Diese beschreibt die Wahrscheinlichkeit, dass ein Modell λ die Beobachtungsfolge $\mathbf{O} = (O_1, O_2, \dots, O_T)$ entlang eines beliebigen Pfades durch die internen Zustände produziert hat. Sie gibt damit an, wie gut ein Modell eine vorliegende Beobachtungsfolge erklären kann und ist ein geeignetes Maß für eine Klassifikation.

Eine naheliegende Lösung des Problems erhält man durch Auflistung aller möglichen Pfade der Länge T durch das Modell. Für jeden einzelnen Pfad $\mathbf{s} = (s_1, s_2, \dots, s_T)$ lässt sich die Wahrscheinlichkeit, dass dieser Pfad die Beobachtungsfolge erzeugt hat, als Produkt der Emissionswahrscheinlichkeiten entlang des Pfades angeben.

$$P(\mathbf{O} | \mathbf{s}, \lambda) = \prod_{t=1}^T b_{s_t}(O_t) \quad (3.6)$$

Die Wahrscheinlichkeit, dass dieser Pfad aufgetreten ist, ergibt sich aus der Anfangsverteilung und den Übergangswahrscheinlichkeiten mit der Konvention $a_{s_0, i} := \pi_i$ zu

$$P(\mathbf{s} | \lambda) = \pi_{s_1} \prod_{t=2}^T a_{s_{t-1}, s_t} = \prod_{t=1}^T a_{s_{t-1}, s_t}. \quad (3.7)$$

Die Verbundwahrscheinlichkeit, dass ein bestimmter Pfad aufgetreten ist und die vorliegende Beobachtungsfolge erzeugt hat, berechnet sich aus dem Multiplikationssatz.

$$P(\mathbf{O}, \mathbf{s} | \lambda) = P(\mathbf{O} | \mathbf{s}, \lambda) P(\mathbf{s} | \lambda) = \prod_{t=1}^T a_{s_{t-1}, s_t} b_{s_t}(O_t) \quad (3.8)$$

Für die Produktionswahrscheinlichkeit auf einem beliebigen Pfad muss noch über alle möglichen Pfade summiert werden.

$$P(\mathbf{O} | \lambda) = \sum_{\mathbf{s}} P(\mathbf{O}, \mathbf{s} | \lambda) \quad (3.9)$$

Die Komplexität dieser Berechnungsvorschrift wächst allerdings exponentiell in der Länge T des Beobachtungsvektors und ist selbst für kleine Modelle in der Praxis kaum umsetzbar.⁸

⁸Rabiner rechnet in [RJ86] vor, dass man bereits für ein kleines Modell mit 5 Zuständen und einer Beobachtungslänge von 100 Zeitschritten in die Größenordnung von 10^{72} Rechenoperationen kommt.

3.3.3.1 Forward-Algorithmus

Eine effiziente Lösung zur Berechnung der Produktionswahrscheinlichkeit liefert der *Forward-Algorithmus*. Die Grundidee besteht in der Ausnutzung der Markov-Eigenschaft der Gedächtnislosigkeit, sowie der Anwendung des Optimalitätsprinzips nach Bellman [Bel57]. Da die Geschichte des Prozesses für eine Prognose in die Zukunft nicht notwendig ist, können alle Pfade durch das Modell parallel betrachtet und berechnet werden.

Dazu wird als Hilfsvariable die Vorwärtsvariable $\alpha_t(i)$ eingeführt, die die Wahrscheinlichkeit angibt, den Anfang der Beobachtungsfolge bis zum Zeitpunkt t gesehen zu haben, und sich zu diesem Zeitpunkt in Zustand i zu befinden:

$$\alpha_t(i) = P(O_1, O_2, \dots, O_t, s_t = i \mid \lambda) \quad (3.10)$$

Im ersten Zeitschritt wird die Vorwärtsvariable für jeden Zustand direkt aus Startwahrscheinlichkeiten und der Emissionswahrscheinlichkeit der ersten Beobachtung gebildet.

$$\alpha_1(i) = \pi_i b_i(O_1) \quad (3.11)$$

In allen folgenden Zeitschritten kann die Vorwärtsvariable induktiv aus dem letzten Zeitschritt berechnet werden. Der Übergang in den Zustand i kann aus allen vorangegangenen Zuständen mit der jeweiligen Übergangswahrscheinlichkeit erfolgen. Die verschiedenen Möglichkeiten sind also additiv verknüpft. Die zusätzliche Bedingung, im neuen Zustand eine entsprechende Beobachtung zu machen, wird wie zuvor durch die Emissionswahrscheinlichkeit beschrieben. Die Induktionsvorschrift lautet demnach

$$\alpha_{t+1}(i) = \sum_{j=1}^N \alpha_t(j) a_{j,i} b_i(O_{t+1}) \quad (3.12)$$

mit N als Anzahl der Zustände. Wenn die Induktion am Ende der Beobachtungsfolge angekommen ist, liegt ein Satz von Vorwärtsvariablen entsprechend der Anzahl der Zustände vor, die die Wahrscheinlichkeiten repräsentieren, die Beobachtungsfolge komplett gesehen zu haben und am Ende im jeweiligen Zustand angekommen zu sein. Um die gesuchte Wahrscheinlichkeit, die Beobachtungsfolge gesehen zu haben und sich am Ende in einem beliebigen Zustand zu befinden, zu erhalten, muss über alle Zustände summiert werden.

$$P(\mathbf{O} \mid \lambda) = \sum_{i=1}^N \alpha_T(i) \quad (3.13)$$

Insgesamt müssen NT Vorwärtsvariablen berechnet und die Abschluss-Summation in (3.13) ausgeführt werden. Während der Rechnung müssen $2N$ Werte zwischengespeichert werden. Der Forward-Algorithmus wächst quadratisch in der (überschaubaren) Anzahl der Zustände und lediglich linear in der Anzahl der Zeitschritte und stellt damit eine äußerst rechen- und speichereffiziente Lösung für das Evaluierungsproblem bereit.

3.3.4 Optimale Produktionswahrscheinlichkeit

Die Produktionswahrscheinlichkeit ist nicht die einzige mögliche Kenngröße zur Bewertung des Evaluierungsproblems. Eine alternative Herangehensweise ist die Betrachtung einer *optimalen Produktionswahrscheinlichkeit*. Dies ist die höchste Produktionswahrscheinlichkeit, die entlang eines einzelnen Pfades auftritt.

$$P(\mathbf{O}, \mathbf{s}^* | \lambda) = \max_{\mathbf{s}} P(\mathbf{O}, \mathbf{s} | \lambda) \quad (3.14)$$

Dieses Maß kann also herangezogen werden, um zu identifizieren, wie gut die Beobachtungsfolge vom besten Pfad erklärt wird. Es stellt deshalb eine Spezialisierung gegenüber der Produktionswahrscheinlichkeit dar, die besagt, wie gut die Beobachtungen im Mittel auf das Modell passen. Auch dieses speziellere Maß ist geeignet für eine Klassifikation.

In diesem Fall ist eine Auflistung der individuellen Produktionswahrscheinlichkeiten nach Gleichung (3.8) zwar ebenfalls möglich, aber ebensowenig praktikabel.

Analoge Überlegungen zum Forward-Algorithmus führen auf die Einführung der Hilfsvariablen $\delta_t(i)$, die die maximale Wahrscheinlichkeit beschreibt, den Anfang der Beobachtungssequenz auf einem beliebigen, aber festen Pfad gesehen zu haben und zum Zeitpunkt t in Zustand i zu sein.

$$\delta_t(i) = \max_{s_1, s_2, \dots, s_{t-1}} P(O_1, O_2, \dots, O_t, s_1, s_2, \dots, s_{t-1}, s_t = i | \lambda) \quad (3.15)$$

Der Initialisierungsschritt wird analog zum Forward-Algorithmus ausgeführt.

$$\delta_1(i) = \pi_i b_i(O_1) \quad (3.16)$$

Wenn die höchsten individuellen Produktionswahrscheinlichkeiten für einen Zeitpunkt t vorliegen, kann durch Induktion der nächste Zeitschritt berechnet werden. Der Pfad wird in diejenige Richtung verlängert, die gewichtet mit der entsprechenden Übergangswahrscheinlichkeit die maximale partielle Produktionswahrscheinlichkeit

ergibt. Anschließend muss noch die neue Beobachtung gemacht werden.

$$\delta_{t+1}(j) = \max_i \{ \delta_t(i) a_{i,j} \} b_j(O_{t+1}). \quad (3.17)$$

Im Zeitpunkt T angekommen erhält man als Ergebnis die optimalen Produktionswahrscheinlichkeiten für Pfade, die in den einzelnen Zuständen enden. Die optimale Produktionswahrscheinlichkeit der Beobachtungsfolge selbst ist der Gewinner unter diesen Pfaden.

$$P(\mathbf{O}, \mathbf{s}^* | \lambda) = \max_i \delta_T(i) \quad (3.18)$$

Wie man sieht, ist die Berechnungsvorschrift für die optimale Produktionswahrscheinlichkeit völlig analog zum Forward-Algorithmus, mit dem Unterschied, dass Summen durch den Maximum-Operator ersetzt werden. Aus Gründen, die in Abschnitt 3.4.1 angesprochen werden, macht das die Berechnung der optimalen Produktionswahrscheinlichkeit noch ein wenig recheneffizienter als die Berechnung der Produktionswahrscheinlichkeit.

3.3.5 Dekodierung

Auch für das Dekodierungsproblem sind verschiedene Ansätze denkbar, je nach Optimalitätskriterium für einen „besten“ Pfad.

3.3.5.1 Maximierung der Anzahl der richtigen individuellen Zustände: Der Forward-Backward-Algorithmus

Durch die Vorwärtsvariable liegen bereits Informationen über das Auftreten des Anfangs der Beobachtungsfolge vor. Analog dazu können Informationen über das Ende der Beobachtungsfolge gewonnen werden, indem man die Rückwärtsvariable $\beta_t(i)$ definiert.

$$\beta_t(i) = P(O_{t+1}, O_{t+2}, \dots, O_T | s_t = i, \lambda) \quad (3.19)$$

Diese ist fast spiegelbildlich zur Vorwärts-Variablen und gibt die Wahrscheinlichkeit dafür an, dass das Modell vom Zustand i aus den Rest der Beobachtungsfolge erzeugt.

Die Induktion läuft in diesem Fall vom Zeitpunkt T aus rückwärts. Als Initialisierung wird die Wahrscheinlichkeit, vom Zeitpunkt T aus keine weitere Beobachtung mehr zu machen, per Definition zu eins gesetzt. Die weiterführende Induktion geschieht wiederum analog zum Forward-Algorithmus, ebenso der Rekursionsabschluss.

$$\beta_T(i) := 1 \quad (3.20)$$

$$\beta_t(i) = \sum_{j=1}^N a_{i,j} \beta_{t+1}(j) b_j(O_{t+1}) \quad (3.21)$$

$$P(\mathbf{O} | \lambda) = \sum_{i=1}^N \pi_i \beta_1(i) b_i(O_1) \quad (3.22)$$

Dieser Algorithmus wird auch *Backward-Algorithmus* genannt und liefert nicht nur eine alternative Berechnungsmethode der Produktionswahrscheinlichkeit, sondern kann mit dem Forward-Algorithmus zum *Forward-Backward-Algorithmus* verknüpft werden, bei dem zu jedem Zeitpunkt sowohl Vorwärts- als auch Rückwärtsvariablen berechnet werden.

Um die zu erwartende Anzahl der richtigen Zustände zu maximieren, wird als weitere Hilfsgröße die a-posteriori Wahrscheinlichkeit des Zustands i zum Zeitpunkt t berechnet, die sich direkt aus den Vorwärts- und Rückwärtsvariablen ergibt.

$$\gamma_t(i) = P(S_t = s_i | \mathbf{O}, \lambda) = \frac{P(S_t = s_i, \mathbf{O} | \lambda)}{P(\mathbf{O} | \lambda)} = \frac{\alpha_t(i) \beta_t(i)}{P(\mathbf{O} | \lambda)} \quad (3.23)$$

In jedem Zeitpunkt erhält man für den jeweils wahrscheinlichsten Zustand

$$s_t = \arg \max_i \gamma_t(i). \quad (3.24)$$

Die Produktionswahrscheinlichkeit im Nenner von Gleichung (3.23) ist konstant, ihre Kenntnis ist für die Auswertung der Maxima nicht notwendig.

Die Herangehensweise, für jeden Zeitschritt individuell den wahrscheinlichsten Zustand zu berechnen, birgt jedoch einen entscheidenden Nachteil. Falls nicht alle Zustandsübergänge möglich sind, d.h. falls mindestens ein Element der Zustandsübergangsmatrix $a_{i,j}$ null ist, kann es passieren, dass die nach diesem Kriterium „beste“ Zustandssequenz selbst kein möglicher Pfad durch das Modell ist. Auch wenn aus diesem Grund der im Folgenden beschriebene Viterbi-Algorithmus für Dekodierungsaufgaben meist den Vorzug erhält, ist der Forward-Backward-Algorithmus ein wichtiger Bestandteil von HMM Trainingsalgorithmen (Abschnitt 3.3.6).

3.3.5.2 Pfad, auf dem die beste Produktionswahrscheinlichkeit erzielt wurde: Der Viterbi-Algorithmus

Als bester garantiert möglicher Pfad \mathbf{s}^* wird der Weg durch das Modell definiert, der die a-posteriori Wahrscheinlichkeit der Beobachtungsfolge bei gegebenem Modell maximiert.

$$\mathbf{s}^* = \arg \max_{\mathbf{s}} P(\mathbf{s} | \mathbf{O}, \lambda) \quad (3.25)$$

Mit dem Satz von Bayes und der Tatsache, dass die Maximierung von der konstanten Produktionswahrscheinlichkeit $P(\mathbf{O} | \lambda)$ unabhängig ist, kann diese Beziehung auf die optimale Produktionswahrscheinlichkeit $P(\mathbf{O}, \mathbf{s}^* | \lambda)$ zurückgeführt werden, für die schon ein effizientes Lösungsverfahren beschrieben wurde.

$$\mathbf{s}^* = \arg \max_{\mathbf{s}} P(\mathbf{s} | \mathbf{O}, \lambda) = \arg \max_{\mathbf{s}} \frac{P(\mathbf{O}, \mathbf{s} | \lambda)}{P(\mathbf{O} | \lambda)} = \arg \max_{\mathbf{s}} P(\mathbf{O}, \mathbf{s} | \lambda) \quad (3.26)$$

In der Tat beginnt der Viterbi-Algorithmus mit der Bestimmung der optimalen Produktionswahrscheinlichkeit nach Abschnitt 3.3.4. Nach dieser Rechnung ist der letzte Zustand des optimalen Pfades bekannt.

$$s_T^* = \arg \max_i \delta_T(i) \quad (3.27)$$

Nach dem Optimalitätsprinzip von Bellman kann der Pfad nun von der letzten Station rückwärts aufgebaut werden, indem in jedem Zeitschritt in Richtung der mit der jeweiligen Übergangswahrscheinlichkeit gewichteten partiell optimalen Produktionswahrscheinlichkeit $\delta_t(i)$ gegangen wird. Dieser Schritt wird *Backtracking* genannt.

$$s_t^* = \arg \max_i \delta_t(i) a_{i, s_{t+1}^*} \quad (3.28)$$

Mit dem Viterbi-Algorithmus [Vit67] steht ein recheneffizientes Lösungsverfahren für das Dekodierungsproblem bereit. Der Aufwand ist durch den Backtracking-Schritt jedoch leicht höher als bei der Auswertung der Produktionswahrscheinlichkeit. Insbesondere müssen alle Hilfsgrößen $\delta_t(i)$ zwischengespeichert werden.

3.3.6 Training

Ähnlich wie bei Evaluierungs- und Dekodierungsproblem muss beim Training zunächst das Optimalitätskriterium definiert werden. Hierfür kommen beispielsweise

die Produktionswahrscheinlichkeit oder die optimale Produktionswahrscheinlichkeit in Frage.

Leider sind keine Verfahren zur global-optimalen Strukturoptimierung von HMMs basierend auf Trainingsdaten bekannt. Die gängigen Verfahren liefern eine Parameteroptimierung, d.h. es wird davon ausgegangen, dass die Struktur des HMM selbst (Anzahl der Zustände, mögliche bzw. unmögliche Zustandsübergänge, Art der Emissionsverteilungen) z. B. durch Expertenwissen vorgegeben ist [Fin03]. Der Trainingsalgorithmus liefert dann eine Schätzung für die von null verschiedenen Elemente der Zustandsübergangsmatrix \mathbf{A} sowie für die Parameter der zustandsspezifischen Emissionsverteilungen b_i .

Für die global-optimale Parameterbestimmung eines HMM ist ebenfalls keine allgemeingültige Lösung bekannt. Die Optimierungsverfahren garantieren lediglich eine Wachstumstransformation, d.h. ein gegebenes, initial parametrisiertes Modell wird iterativ verbessert, bis der Parametersatz gemessen am Optimierungskriterium einen Fixpunkt oder ein sonstiges Abbruchkriterium erreicht.

In der vorliegenden Arbeit wurde als Optimierungskriterium die Produktionswahrscheinlichkeit gewählt. Das gebräuchliche Verfahren für diesen in der Praxis häufig genutzten Fall ist der Baum-Welch-Algorithmus.

3.3.6.1 Training bezüglich der Produktionswahrscheinlichkeit: Der Baum-Welch-Algorithmus

Der Baum-Welch-Algorithmus [BPSW70] geht von einem initial parametrisierten Modell λ aus und erzeugt ein neues Modell $\hat{\lambda}$, das der Wachstumstransformation

$$P(\mathbf{O} | \hat{\lambda}) \geq P(\mathbf{O} | \lambda) \quad (3.29)$$

genügt. Das Gleichheitszeichen in Beziehung (3.29) beschreibt das Erreichen eines lokalen Optimums.

Im Laufe der Optimierung werden die Parameter durch ihre jeweiligen bedingten Erwartungswerte bei gegebenem bisherigen Modell λ und Trainingsdaten ersetzt.

Bei der Schätzung der Übergangswahrscheinlichkeiten liegt die Idee zugrunde, von anhand der Trainingsdaten zu erwartenden relativen Häufigkeiten für Emissionen und Zustandsübergänge auf Wahrscheinlichkeiten zu schließen. Bei der Vorstellung des Forward-Backward-Algorithmus wurde die Hilfsgröße $\gamma_t(i)$ eingeführt, die besagt, wie wahrscheinlich es ist, sich zum Zeitpunkt t in Zustand i zu befinden bei gegebenem

Modell und Beobachtungsfolge (Gleichung (3.23)). Als neue Hilfsgröße wird analog die Wahrscheinlichkeit eingeführt, zum Zeitpunkt t einen Übergang vom Zustand i in den Zustand j zu vollziehen, $\gamma_t(i, j)$. Diese kann ebenfalls mit den bereits bekannten Vorwärts- und Rückwärtsvariablen bestimmt werden, wie sich durch Einsetzen der Definitionsgleichungen für die Hilfsvariablen zeigen lässt. Bei den Parametern $a_{i,j}$ und b_j handelt es sich um die jeweiligen Werte des vorherigen, zu verbessernden Modells.

$$\gamma_t(i, j) = P(S_t = s_i, S_{t+1} = s_j | \mathbf{O}, \lambda) = \frac{\alpha_t(i) a_{i,j} b_j(O_{t+1}) \beta_{t+1}(j)}{P(\mathbf{O} | \lambda)} \quad (3.30)$$

Es ergibt sich eine neue, verbesserte Schätzung der Übergangswahrscheinlichkeit $\hat{a}_{i,j}$ aus der relativen Häufigkeit des betreffenden Zustandsübergangs, also aus dem Quotient der erwarteten Anzahl der Übergänge vom Zustand i in den Zustand j und der Anzahl der Übergänge von Zustand i in irgend einen anderen Zustand. Da außer dem letzten Zeitschritt zu jedem Zeitpunkt ein Zustandsübergang erfolgt⁹, ist letzteres gleichbedeutend mit der Anzahl der Zeitschritte, an denen das Modell in Zustand i war.

$$\hat{a}_{i,j} = \frac{\sum_{t=1}^{T-1} P(S_t = s_i, S_{t+1} = s_j | \mathbf{O}, \lambda)}{\sum_{t=1}^{T-1} P(S_t = s_i | \mathbf{O}, \lambda)} = \frac{\sum_{t=1}^{T-1} \gamma_t(i, j)}{\sum_{t=1}^{T-1} \gamma_t(i)} \quad (3.31)$$

Sofern die Startwahrscheinlichkeiten π mitgeschätzt werden sollen, können diese aus

$$\pi_i = P(S_1 = s_i | \mathbf{O}, \lambda) = \gamma_1(i) \quad (3.32)$$

erhalten werden.

Das Vorgehen bei der Schätzung der Emissionsverteilungen geschieht analog. Im Diskreten wird die Emissionswahrscheinlichkeit des Symbols o_k aus dem Zustand i über die relative Häufigkeit angenähert. Sie ergibt sich damit als Quotient aus der erwarteten Anzahl der Emissionen von o_k aus dem Zustand i durch die erwartete Anzahl der Emissionen irgend eines Symbols aus diesem Zustand. Da pro Zeitschritt eine Emission beobachtet werden kann, kann letztere wiederum auf die jeweiligen

⁹Wie bei Markov-Ketten üblich wird ein Verbleiben in einem Zustand als Übergang in den selben Zustand modelliert.

Aufenthaltswahrscheinlichkeiten $\gamma(i)$ zurückgeführt werden.

$$\begin{aligned}\hat{b}_i(o_k) &= \frac{\sum_{t=1}^T P(S_t = s_i, O_t = o_k | \mathbf{O}, \lambda)}{\sum_{t=1}^T P(S_t = s_i | \mathbf{O}, \lambda)} = \frac{\sum_{t:O_t=o_k} P(S_t = s_i | \mathbf{O}, \lambda)}{\sum_{t=1}^T P(S_t = s_i | \mathbf{O}, \lambda)} \\ &= \frac{\sum_{t:O_t=o_k} \gamma_t(i)}{\sum_{t=1}^T \gamma_t(i)}\end{aligned}\quad (3.33)$$

Bei der Modellierung der Emissionen mit kontinuierlichen Verteilungen ist das Vorgehen ähnlich. Sollen z. B. auf Basis von kontinuierlichen Beobachtungen $O_t = \mathbf{x}_t$ für jeden Zustand i Mittelwert $\hat{\mu}_i$ und Kovarianzmatrix $\hat{\Sigma}_i$ einer Normalverteilung trainiert werden, lauten die Schätzgleichungen

$$\hat{\mu}_i = \frac{\sum_{t=1}^T \gamma_t(i) \mathbf{x}_t}{\sum_{t=1}^T \gamma_t(i)} \quad (3.34)$$

$$\hat{\Sigma} = \frac{\sum_{t=1}^T \gamma_t(i) (\mathbf{x}_t - \hat{\mu}_i) (\mathbf{x}_t - \hat{\mu}_i)^T}{\sum_{t=1}^T \gamma_t(i)}. \quad (3.35)$$

Das Training von Misch- oder anderen Verteilungen erfolgt analog, für die konkreten Schätzgleichungen sei auf die weiterführende Literatur verwiesen, z. B. [Fin03; HAH01].

Durch das abwechselnde Schätzen von neuen Zustandsübergangswahrscheinlichkeiten und Emissionsverteilungen erfolgt die Segmentierung der Daten und die Erzeugung von Emissionsverteilungen, die die Daten erklären, simultan. Die Eigenschaft der kombinierten Segmentierung und Klassifikation ist auch während des Trainings sichtbar.

Die Prozedur wird wiederholt, bis ein Abbruchkriterium erreicht wurde. Typischerweise wird abgebrochen, wenn die Produktionswahrscheinlichkeit des neuen Modells nicht mehr signifikant höher als die Produktionswahrscheinlichkeit des Ausgangsmodells ist.

Aus Darstellungsgründen wurde das Training in diesem Kapitel auf Basis einer einzelnen Beobachtungsfolge gezeigt. In der Praxis möchte man HMMs jedoch anhand eines möglichst umfassenden Satzes von Beobachtungsfolgen trainieren, damit genügend Daten vorhanden sind, um alle Parameter realistisch schätzen zu

können. Liegen K Beobachtungsfolgen

$$\mathbf{O} = (\mathbf{O}^{(1)}, \mathbf{O}^{(2)}, \dots, \mathbf{O}^{(K)}) \quad (3.36)$$

vor, erweitert sich das Optimierungskriterium auf eine Verbundproduktionswahrscheinlichkeit

$$P(\mathbf{O} | \lambda) = \prod_{k=1}^K P(\mathbf{O}^{(k)} | \lambda) \quad (3.37)$$

Die Vorschriften für das Training bleiben dabei prinzipiell erhalten, es müssen jedoch alle Beobachtungsfolgen in den Statistiken aufakkumuliert werden. Die Schätzgleichungen enthalten dann eine zusätzliche äußere Summation über die Beobachtungsfolgen.

In jedem Fall benötigt das Training ein initial parametrisiertes Modell, dessen Güte im Allgemeinen das Trainingsresultat wesentlich bestimmen kann. Während eine zufällige oder gleichförmige Wahl der Startwahrscheinlichkeiten und der Übergangswahrscheinlichkeiten meist unkritisch ist, bietet es sich an, bei der Wahl der Parameter der Emissionsverteilungen Vorwissen einzubringen [Rab89]. Dies kann z. B. durch eine auf domänenspezifischem Wissen beruhende manuelle Vorsegmentierung der Daten erfolgen. Bei speziellen Modelltopologien ist solch eine Vorsegmentierung und initiale Parametrierung unter Ausnutzung von Struktureigenschaften auch automatisch möglich, wie im Folgenden für ein lineares Modell gezeigt wird.

3.3.7 Modelltopologie

Durch das Setzen von Elementen der Übergangswahrscheinlichkeitsmatrix \mathbf{A} auf null können einzelne Zustandsübergänge verboten werden [Fin03; Rab89]. Eine häufige Anwendung solcher Einschränkungen besteht in der Abbildung eines (meist zeitlich interpretierten) Fortschritts im Modell selbst.

In Abb. 3.3 sind verschiedene Grade von Einschränkungen gezeigt, die einen Fortschritt im Modell erzeugen. Zu jedem Graphen ist schematisch die Belegung der Zustandsübergangsmatrix gezeigt.

Die allgemeinste Form ist das *ergodische* Modell, bei dem von jedem Zustand direkt in jeden anderen Zustand übergegangen werden kann.¹⁰ Die zugehörige Matrix ist voll besetzt.

¹⁰Streng genommen nennt man ein Modell dann ergodisch, wenn ein beliebiger Zustand von jedem anderen Zustand aus in einer endlichen Anzahl von Schritten erreichbar ist. Im Zusammenhang

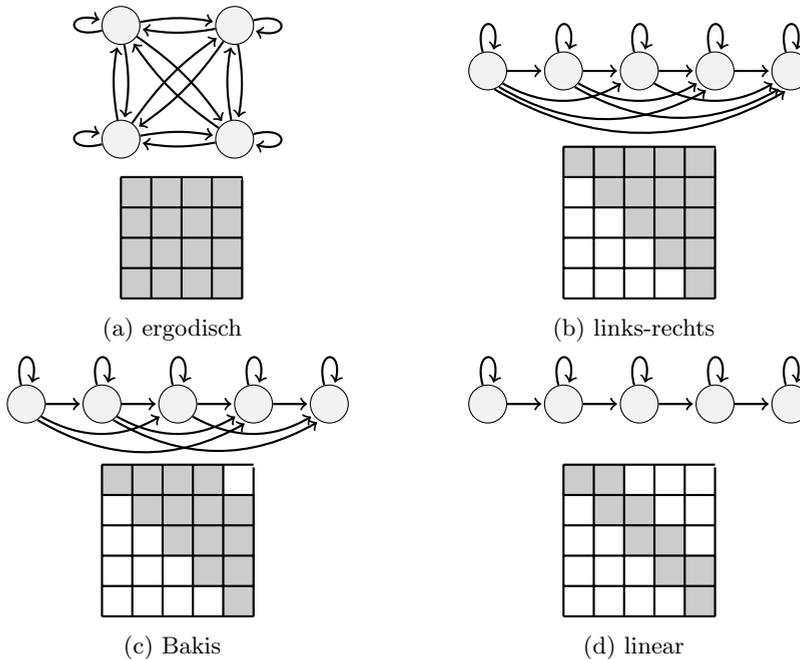


Abbildung 3.3: Einige Topologien von Hidden-Markov-Modellen. Unter dem Zustandsgraph ist jeweils die Matrix der Zustandsübergangswahrscheinlichkeiten als Gitter dargestellt. Dunkle Zellen sind von null verschiedene Werte, helle Zellen haben den Wert null.

Modelle, die einen Fortschritt repräsentieren, werden *links-rechts*-Modell genannt. Sie haben die Eigenschaft, dass bei fortschreitender Zeit auch der Index des Zustands, in dem man sich befindet, monoton wächst. Ein „Zurückgehen“ in Zustände mit kleinerem Index ist nicht mehr möglich. Die Zustandsübergangsmatrix wird zu einer oberen Dreiecksmatrix:

$$a_{i,j} = 0 \quad \forall \quad j < i. \quad (3.38)$$

Eine weitere Einschränkung stellt das *Bakis*-Modell dar. Hier wird zusätzlich die Anzahl der Zustände Δ , die übersprungen werden können, beschränkt. Die Zustandsübergangsmatrix ist also nur noch auf der Hauptdiagonalen und einer entsprechenden

mit HMMs wird diese Anzahl in der Literatur meist auf einen einzigen Schritt beschränkt und ist damit restriktiver als die allgemeine Definition [Fin03].

Anzahl von oberen Nebendiagonalen besetzt.

$$a_{i,j} = 0 \quad \forall \quad j < i \quad \vee \quad j - i > \Delta \quad (3.39)$$

Die einfachste Modellstruktur sind *lineare* Modelle. Alle Zustände müssen sequentiell durchlaufen werden, das Überspringen von einzelnen Zuständen oder Zustandsfolgen ist nicht mehr gestattet. Die Zustandsübergangsmatrix ist nur noch auf der Hauptdiagonalen und der ersten oberen Nebendiagonalen besetzt.

$$a_{i,j} = 0 \quad \forall \quad (j \neq i \quad \wedge \quad j \neq i + 1) \quad (3.40)$$

Im Gegensatz zu ergodischen Modellen werden bei Modellen, die einen Fortschritt abbilden, die Startwahrscheinlichkeiten meist nicht als zu trainierende Modellparameter aufgefasst. Um zu testen, wie gut eine Beobachtungsfolge den Fortschritt im Modell widerspiegelt, wird die Startwahrscheinlichkeit auf den ersten Zustand konzentriert.

$$\pi_i = \begin{cases} 0 & \text{für } i \neq 1 \\ 1 & \text{für } i = 1 \end{cases} \quad (3.41)$$

In diesem Fall lassen sich auch für die mögliche Segmentierung der Daten Einschränkungen ableiten. In einer Beobachtungsfolge, die für das Training verwendet werden und damit das komplette Modell widerspiegeln soll, entsprechen Segmente von einzelnen Beobachtungen sequentiell fortlaufenden Zuständen im Modell. Dieser Umstand kann ausgenutzt werden, um in Abwesenheit von zusätzlichem Vorwissen ein initial parametrisiertes Modell für das Training zu generieren. Dafür werden die Beobachtungsfolgen segmentiert, indem einzelne Beobachtungen gleichmäßig auf die Zustände aufgeteilt werden. Die initialen Parameter der Emissionsverteilungen können dann anhand der relativen Häufigkeiten geschätzt werden. Eine Gewinnung des initial parametrisierten Modells ist damit ebenfalls automatisiert möglich. Diese Vorgehensweise erzeugt insbesondere für lineare Modelle oft gute Anfangsschätzungen für die spätere Optimierung im Training.

3.3.8 Thematische Einordnung in die Klasse der bayesschen Netze und Analogie zu Kalman-Filter-Modellen

HMMs lassen sich als Spezialisierung eines dynamischen bayesschen Netzes (DBNs) ansehen, wobei pro Zeitschritt ein verborgener diskreter Knoten den Zustand und

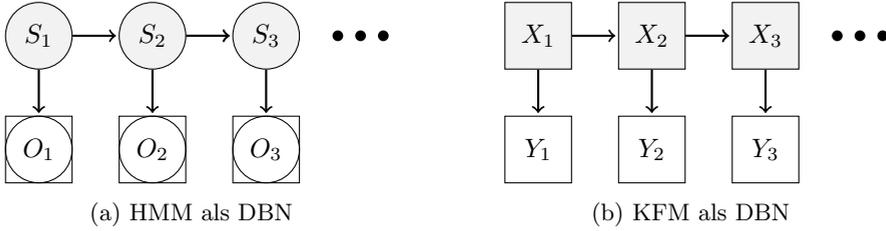


Abbildung 3.4: Darstellung eines Hidden-Markov-Modells (a) und eines Kalman-Filter-Modells (b) als dynamisches bayessches Netz. Es wurden jeweils drei Zeitschritte „abgerollt“.

ein sichtbarer diskreter oder kontinuierlicher Knoten die Beobachtung repräsentiert.

Ähnlich wie HMMs lassen sich auch Kalman-Filter-Modelle (KFM) als Spezialisierung von DBNs auffassen. In einer für die Zustandsschätzung geeigneten Form ohne äußeren Eingang lauten die Schätzgleichungen dafür, dass sich das System zum Zeitpunkt t in Zustand \mathbf{x}_t befindet und die Messung \mathbf{y}_t erhalten wird

$$P(\mathbf{X}_t = \mathbf{x}_t \mid \mathbf{X}_{t-1} = \mathbf{x}_{t-1}) = \mathcal{N}(\mathbf{x}_t; \mathbf{A} \mathbf{x}_{t-1}, \mathbf{Q}) \quad (3.42)$$

$$P(\mathbf{Y}_t = \mathbf{y}_t \mid \mathbf{X}_t = \mathbf{x}_t) = \mathcal{N}(\mathbf{y}_t; \mathbf{C} \mathbf{x}_t, \mathbf{R}). \quad (3.43)$$

Hierbei ist \mathbf{A} die Zustandsübergangsmatrix, \mathbf{C} die Messmatrix und \mathbf{Q} und \mathbf{R} sind Kovarianzmatrizen für Modell- und Messrauschen. Die Repräsentierung als DBN kann völlig analog zu HMMs erfolgen, jedoch mit anderen Einschränkungen (z. B. können Emissionen von HMMs beliebigen Verteilungen folgen, nicht nur der Normalverteilung).

Abb. 3.4 (a) und (b) stellen jeweils drei Zeitschritte eines HMM und KFM als dynamisches bayessches Netz dar. Grau schattierte Blöcke sind jeweils verborgen, kreisförmige Knoten deuten auf diskrete Elemente hin, während rechteckige Blöcke kontinuierliche Elemente darstellen (die Beobachtungen O_i können diskret oder kontinuierlich sein). Die Ähnlichkeiten in der Topologie sind offensichtlich. Sowohl HMM als auch KFM sind einfache DBNs, mit dem Unterschied, dass erstere diskret und letztere kontinuierlich in den Zuständen sind.

Näheres zur vereinheitlichten Behandlung von HMMs und KFM mit Methoden von dynamischen bayesschen Netzen kann in [Mur02a] nachgelesen werden. Dies ist vor allem bei Erweiterungen und Varianten von HMMs (z. B. auto-regressiv, semi-Markov, mixed-memory, buried) oder KFM (z. B. auto-regressiv, switching) bedeutend, wird im Kontext dieser Arbeit jedoch nicht weiter verfolgt.

3.4 Implementierungsfragen bei HMMs

Die Algorithmen zum Umgang mit HMMs sind in ihrer bisher dargestellten Form zwar anschaulich, können jedoch in dieser Form nicht direkt in einem Digitalrechner umgesetzt werden.

3.4.1 Numerische Stabilität: Logarithmierung und Skalierung von Wahrscheinlichkeiten

Bei der Betrachtung der Rekursionsvorschriften von wichtigen Hilfsgrößen, beispielsweise der Vorwärtsvariablen $\alpha_t(i)$ (3.12), fällt auf, dass in großem Umfang Produkte bestehend aus Übergangswahrscheinlichkeiten und Emissionswahrscheinlichkeiten gebildet werden müssen. Beide Größen sind meist kleiner, oft sogar deutlich kleiner eins. Bei steigender Länge der Beobachtungsfolge streben die einzelnen Produkte schnell gegen null. Bereits bei moderat langen Beobachtungsfolgen von etwa 100 Elementen und ansonsten gutmütig parametrisierten Modellen kommt man in Grenzbereiche, in denen selbst eine doppelte Rechengenauigkeit mit 64 Bit Gleitkommadarstellung nicht mehr zur Abdeckung des benötigten Genauigkeitsbereiches genügt. Maßnahmen zur numerischen Stabilisierung sind daher bei der Implementierung zwingend notwendig.

Eine gängige Methode, um den Zahlenbereich zwischen null und eins aufzuweiten und damit die Darstellungsgenauigkeit von heutigen Digitalrechnern besser auszunutzen, besteht in der Transformation von Wahrscheinlichkeiten und Dichten in den logarithmischen Bereich [Fin03].

$$\tilde{p} = \ln p \quad (3.44)$$

Damit wird der Bereich zwischen null und eins aufgeweitet in den Bereich von negativ unendlich bis null.

$$[0; 1] \quad \mapsto \quad [\ln(0); \ln(1)] = [-\infty; 0] \quad (3.45)$$

Bei kontinuierlichen HMMs, deren Wahrscheinlichkeitsdichten auch Werte größer eins annehmen können, wird sogar prinzipiell der gesamte Zahlenbereich ausgenutzt. Dieser Vorteil wird erkaufte durch eine notwendige Sonderbehandlung der Werte null und unendlich, da der Logarithmus von null nicht definiert ist und per Konvention auf negativ unendlich abgebildet wird.

Die Rechnung im logarithmischen Bereich ist besonders für Algorithmen geeignet,

die hauptsächlich aus Multiplikationen und Extremwertoperationen bestehen. Da Multiplikationen im logarithmischen Bereich zu Additionen werden und Additionen auf Rechnerarchitekturen oft schneller als Multiplikationen sind, kann dadurch unter Umständen sogar die Recheneffizienz gesteigert werden. Da die Logarithmierung eine streng monotone Operation ist, bleiben Extremwertoperatoren unberührt.

Ein Beispiel für einen Algorithmus, der für den logarithmischen Bereich sehr gut geeignet ist, ist der Viterbi-Algorithmus, Kapitel 3.3.5.2. Beispielsweise wird aus der Darstellung der partiellen Pfadwahrscheinlichkeiten δ

$$\delta_{t+1}(j) = \max_i \{\delta_t(i) a_{i,j}\} b_j(O_{t+1}).$$

im logarithmischen Bereich der Ausdruck

$$\tilde{\delta}_{t+1}(j) = \max_i \{\tilde{\delta}_t(i) + \tilde{a}_{i,j}\} + \tilde{b}_j(O_{t+1}). \quad (3.46)$$

Problematischer in Zusammenhang mit Logarithmierung sind Algorithmen, die ihrerseits Additionen erfordern, wie z. B. der Forward-Algorithmus, Kapitel 3.3.3.1. Die Kosten für eine Delogarithmierung, Addition und anschließende Rückführung in den logarithmischen Bereich lassen sich durch Approximation oder geschickte Umformung (z. B. die Kingsbury-Rayner-Formel [KR71]) mildern.

In der vorliegenden Arbeit wurde der alternative Ansatz verfolgt, bei Algorithmen, die viele Additionen benötigen, auf die Logarithmierung zu verzichten und eine gleichmäßigere Ausnutzung des Zahlenbereiches durch geeignete Skalierung mit einem adaptiven Skalierungsfaktor c_t zu erreichen. Dadurch kann die Produktionswahrscheinlichkeit auf numerisch stabilere Art verglichen mit der Darstellung aus Gleichungen (3.10)–(3.13) erreicht werden. Die Idee hinter dem im Folgenden beschriebenen Ansatz geht auf [Rab89] zurück.

Die Initialisierung gliedert sich in drei Schritte:

$$\alpha_1(i) = \pi_i b_i(O_1) \quad (3.47)$$

$$c_1 = \sum_{i=1}^N \alpha_1(i) \quad (3.48)$$

$$\bar{\alpha}_1(i) = \frac{\alpha_1(i)}{c_1} \quad (3.49)$$

Bei der Rekursion wird eine temporäre Hilfsgröße $\bar{\alpha}$ eingeführt und der Skalierungs-

faktor ständig aktualisiert.

$$\bar{\bar{\alpha}}_t(i) = \sum_{j=1}^N (\bar{\alpha}_{t-1}(j) a_{j,i}) b_i(O_t) \quad (3.50)$$

$$c_t = \sum_{i=1}^N \bar{\bar{\alpha}}_t(i) \quad (3.51)$$

$$\bar{\alpha}_t(i) = \frac{\bar{\bar{\alpha}}_t(i)}{c_t} \quad (3.52)$$

Der Rekursionsabschluss kann aus den Skalierungsfaktoren gebildet werden. Um lange Ketten aus Multiplikationen zu vermeiden und konsistent mit der auf Logarithmen basierenden Darstellung beim Viterbi Algorithmus zu sein, wird auch hier die Produktionswahrscheinlichkeit logarithmisch angegeben.

$$\ln(P(\mathbf{O} | \lambda)) = \ln \left(\prod_{t=1}^T c_t \right) = \sum_{t=1}^T \ln(c_t) \quad (3.53)$$

Der Nachweis von Gleichung (3.53) wird in Lemma A.1, Seite 145 geführt.

3.4.2 Minimale Wahrscheinlichkeiten und Modellparameter

Aufgrund der endlichen Menge an Trainingsbeispielen ist es möglich, dass einige diskrete Symbole nicht in ausreichender Menge in den Trainingssequenzen vorkommen, um Emissionsverteilungen schätzen zu können. Dadurch kann im Extremfall die zugehörige Emissionswahrscheinlichkeit in einzelnen Zuständen den Wert null annehmen. Im resultierenden Modell sind dann einzelne Pfade nicht mehr möglich. Die Modellstruktur ändert sich. Diese Änderung kann auf realen physikalischen Gegebenheiten beruhen und damit völlig richtig sein. Es ist aber auch möglich, dass diese Pfade eigentlich erlaubt sein sollten und die Änderung der Modellstruktur weder physikalisch richtig, noch von Expertenwissen oder Design motiviert ist, sondern rein aus praktischen Limitierungen beim Training resultiert.

In letzterem Fall ist der Effekt des Verbots von Pfaden sehr störend. Er kann durch die Bereitstellung von mehr Trainingsbeispielen gemindert werden, was jedoch einerseits nicht immer praktikabel oder möglich ist und andererseits das grundlegende Problem der endlichen Trainingsmenge nicht beseitigt. Aus diesem Grund werden beim Training alle Parameter, bei denen ein Wert von null nicht explizit begründet werden kann, nach unten durch Minimalwahrscheinlichkeiten beschränkt [Rab89].

Für die Parameter von Dichteverteilungen bei kontinuierlichen Emissionen gelten ähnliche Anmerkungen. Auch in diesem Fall können beispielsweise Varianzen einer Normalverteilung unterschätzt werden, wenn nicht genügend Emissionen in einem Zustand trainiert werden. Die Varianzen können ebenfalls sehr klein werden, wenn die Emissionen „zu sicher“ erfolgen und mit einer Normalverteilung nur schlecht angenähert werden können. Da sehr kleine Varianzen unter Umständen trotz Logarithmierung und/oder Skalierung numerische Probleme provozieren können, wurden in dieser Arbeit bei Bedarf Emissionen zusätzlich wie im folgenden beschrieben skaliert.

3.4.3 Skalierung von Emissionen

Werden diskrete Emissionen skaliert, hat das bei entsprechender Anpassung der Wahrscheinlichkeitsverteilung keine Auswirkungen auf die Produktionswahrscheinlichkeit, wie direkt aus den Beziehungen (3.8, 3.9) einsichtig ist. Allerdings bringt die Skalierung auch keinen numerischen Vorteil.

Bei kontinuierlichen Emissionen sei daran erinnert, dass Produktionswahrscheinlichkeiten eigentlich keine Wahrscheinlichkeiten, sondern nur noch Zugehörigkeitswerte sind, die aus Dichtefunktionen berechnet werden. Sei $\mathbf{O} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T)$ eine Beobachtungsfolge aus normalverteilten Emissionen \mathbf{x}_t und \mathbf{C} die Transformationsmatrix einer Koordinatentransformation

$$\mathbf{x}'_t = \mathbf{C} \mathbf{x}_t \quad (3.54)$$

$$\mathbf{x} \sim \mathcal{N}(\mathbf{x}; \boldsymbol{\mu}, \boldsymbol{\Sigma}) \quad \longrightarrow \quad \mathbf{x}' \sim \mathcal{N}(\mathbf{x}'; \mathbf{C} \boldsymbol{\mu}, \mathbf{C} \boldsymbol{\Sigma} \mathbf{C}^T). \quad (3.55)$$

Dann ändert sich die Produktionswahrscheinlichkeit für die transformierte Beobachtungsfolge $\mathbf{O}' = (\mathbf{x}'_1, \mathbf{x}'_2, \dots, \mathbf{x}'_T)$ gemäß Lemma A.2, Seite 146 zu

$$\ln(P(\mathbf{O}' | \lambda')) = \ln(P(\mathbf{O} | \lambda)) - T \ln(\det \mathbf{C}). \quad (3.56)$$

Bei einer orthonormalen Transformation, bei denen die Determinante den Wert eins ergibt, bleiben folglich die Werte der Produktionswahrscheinlichkeiten erhalten. Für allgemeinere Transformationen ist dies nicht unbedingt der Fall. Sollen beispielsweise einzelne Komponenten skaliert werden, um sehr kleinen Varianzen und damit potentiellen numerischen Schwierigkeiten zu begegnen, müssen eventuelle Schwellwerte oder die Interpretation der Produktionswahrscheinlichkeit als Grad der Zugehörigkeit entsprechend Beziehung (3.56) adaptiert werden.

3.5 Modellierung von Fahrmanövern

3.5.1 Training mit kompletten Manövern

Ein Manöver kann als sequentieller Durchlauf von verschiedenen Teilaktionen betrachtet werden, die einzelne Manöverphasen bilden. Bei einem Abbiegevorgang könnte man sich beispielsweise vorstellen, dass zuerst mittels Spiegeln und Schulterblick überprüft wird, ob die Durchführung eines Abbiegevorgangs ohne Gefährdung möglich ist. Die Geschwindigkeit wird angepasst, es beginnt ein Einlenken, an das sich die eigentliche Kurvenfahrt anschließt. Nach der Kurve lenkt der Fahrer wieder aus und zentriert das Fahrzeug im Zielstreifen, wobei die Geschwindigkeit der Umgebung oder einer Wunschvorgabe angepasst wird.

Es muss nochmals betont werden, dass im Zuge der Manövererkennung die einzelnen Manöverphasen nicht identifiziert und modelliert werden müssen – die Markov-Modelle segmentieren die Daten selbständig. Die Andeutung von bedeutungstragenden Teilmanövern soll lediglich die Wahl der Modelltopologie motivieren.

Es ist naheliegend, eine Art von links-rechts-Modellen zu benutzen, um den zeitlichen Fortschritt in den Manöverphasen repräsentieren zu können. Die vorliegende Arbeit wird aufgrund der im Folgenden beschriebenen Vorteile auf die Betrachtung von linearen Modellen (Abb. 3.3d) zur Manövererkennung beschränkt. Die Modelle können also kein Überspringen von Teilmanövern direkt abbilden.¹¹

Dieser Einschränkung gegenüber stehen einige strukturelle Vorteile der sehr einfachen Topologie linearer Modelle. Wie bereits erwähnt, ist es für lineare Modelle am ehesten möglich, automatisiert gute Startmodelle für das Training zu finden. Der wichtigste Grund für die Beschränkung auf lineare Modelle liegt jedoch darin begründet, dass durch eine Extraktion von Teilmodellen eine frühzeitige Manövererkennung erreicht werden kann. Dieser neuartige Ansatz wird in den folgenden Abschnitten dargelegt.

3.5.2 Extraktion von Teilmodellen

In den meisten Anwendungsgebieten von HMMs ist man nach vollständiger Kenntnis von Verläufen von Merkmalsvektoren daran interessiert, ob diese Verläufe eine definierte Klasse repräsentieren und wenn ja welche. Bei der Sprach- oder Handschri-

¹¹Diese Einschränkung ist weniger bedeutend als es zunächst den Anschein hat, wie später gezeigt wird.

terkennung beispielsweise wird eine vorliegende Wortfolge bzw. ein Textausschnitt analysiert und die darin vollständig enthaltenen Worte oder Sätze werden erkannt.

Bei der Manövererkennung für Fahrerassistenzsysteme ist man dagegen in erster Linie nicht daran interessiert, welches Manöver gerade vollendet wurde. Vielmehr ist es das Ziel, möglichst früh zu Manöverbeginn eine Aussage zu erhalten, ob gerade ein Manöver begonnen wird und gegebenenfalls welches Manöver dies ist.

Ein möglicher Ansatz dazu wäre, nicht das gesamte Manöver, sondern nur den Manöverbeginn als Klasse zu verwenden. Dies bedeutet aber, dass es notwendig ist, den Manöverbeginn klar definieren zu können, um daraus Trainingsbeispiele und am Ende ein Modell generieren zu können. Je nach Umgebung und Situation werden Manöver jedoch recht unterschiedlich ausgeführt. Während es schon bei vollständigen Manövern nicht trivial ist, Anfangs- und Endzeitpunkte anzugeben, hat sich bei Teilmanövern herausgestellt, dass es sehr schwierig ist, diese Definition genügend klar manuell zu treffen, um eine erfolgreiche Klassifikation für unterschiedlich ausgeführte Manöver zu gewährleisten. Eigene Voruntersuchungen mit HMMs, die basierend auf gelabelten Teilmanövern trainiert wurden, lieferten in der Tat keine guten Klassifikationsergebnisse.

Um dieses Problem zu umgehen, ist es wünschenswert, vollständige Manöver zu trainieren und das resultierende Modell zu nutzen, um den Manöverbeginn zu detektieren. Da bei links-rechts-Modellen die vorderen Zustände frühen Phasen in den Signalverläufen entsprechen, kann direkt eine Zuordnung zwischen Zuständen und frühen Manöverphasen hergestellt werden.

Bei der Beschränkung auf lineare Modelle ist dazu nicht einmal mehr ein Dekodierungsproblem zu lösen. Vielmehr kann aus einem vollständigen Modell ein Teilmodell extrahiert werden, das für sich genommen die Anfangsphase eines Manövers repräsentiert. Zur Auswertung dieses Modells genügt dann die Lösung des Evaluierungsproblems.

Abb. 3.5 zeigt die Aufteilung eines linearen Modells in zwei Teilmodelle. Beispielhaft wird ein Modell mit fünf Zuständen, das in seiner Gesamtheit ein komplett durchgeführtes Fahrmanöver repräsentieren soll, zwischen dem dritten und vierten Zustand auseinandergeschnitten. Es entstehen zwei Teilmodelle, von denen das erste die ersten Phasen des Manövers abbildet, während das zweite Modell den Rest des Manövers widerspiegelt.

Die Trennung erfolgt durch das Aufteilen der Transitionsmatrix in Blockdiagonalgestalt. Die Blöcke auf der Diagonalen stellen die neuen Transitionsmatrizen der Teilmodelle dar. Die Blöcke auf den Nebendiagonalen werden vernachlässigt.

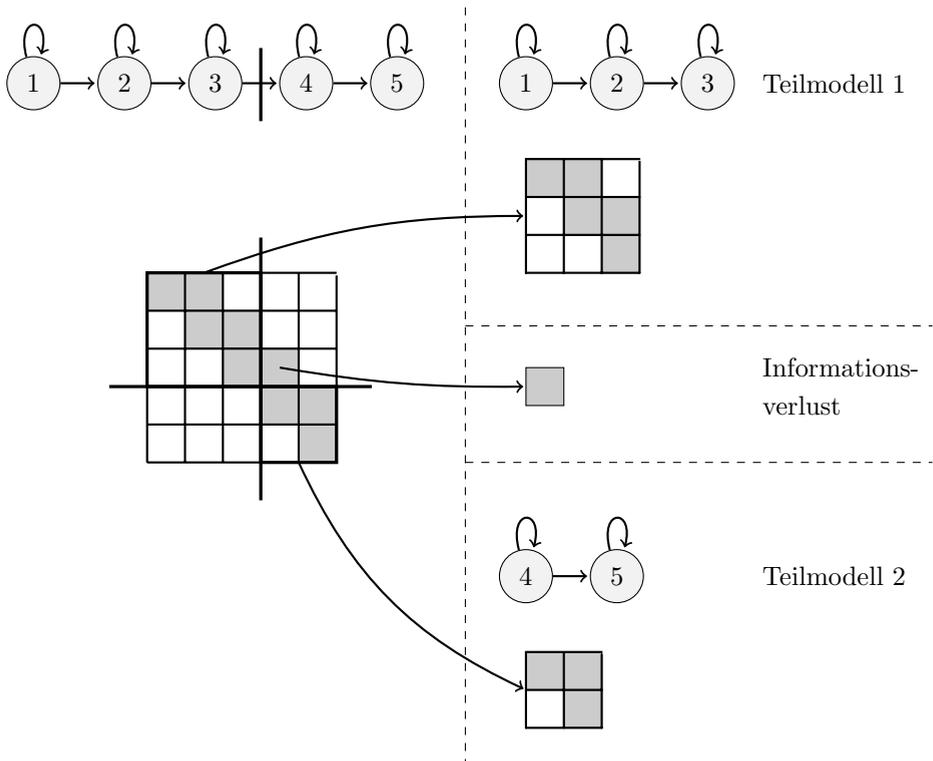


Abbildung 3.5: Aufteilung eines linearen HMM in zwei Teilmodelle.

Bei einem linearen Modell verschwinden beinahe sämtliche Elemente der Nebendiagonalen. Pro Schnitt wird lediglich ein einziger von null verschiedener Wert vernachlässigt. Der sich ergebende Informationsverlust beschreibt gerade die Übergangswahrscheinlichkeit, die durchtrennt wurde. Im linken oberen Block, der die Übergangsmatrix des ersten Modells bildet, muss das letzte Diagonalelement auf den Wert eins gesetzt werden. Die resultierende Übergangsmatrix ist damit wieder eine stochastische Matrix, in diesem Fall mit dem dritten Zustand als Endzustand.

Entscheidend hierbei ist, dass die Teilmodelle bedeutungstragend bleiben. Insbesondere bilden die ersten Zustände immer noch den Manöverbeginn ab. Dies wäre bei einer anderen Modelltopologie nicht unbedingt gegeben. Bei einem allgemeinen links-rechts-Modell oder gar einer ergodischen Struktur wären die Beiträge auf den Nebendiagonalblöcken nicht mehr vernachlässigbar, ohne das Modell selbst grundlegend zu verfälschen. Mit der Beschränkung auf lineare Modelle und dieser Methode können somit gesamte Manöver trainiert, aber trotzdem Teilmanöver mit den effizienten Berechnungsmethoden der Produktionswahrscheinlichkeiten erkannt und klassifiziert werden.

3.5.3 Typischer Pfad, Zeitfenstergröße und erwarteter Erkennungszeitpunkt

Der Umstand, dass die prinzipielle Abfolge der Zustände in einem linearen Modell vorgegeben ist, weil entweder in einem Zustand verblieben oder in den Folgezustand gewechselt werden muss, kann weiter ausgenutzt werden.

Wenn zu jedem Zustand noch die zu erwartende Aufenthaltsdauer angegeben werden kann, ist es möglich, einen *typischen Pfad* durch das Modell anzugeben. Das Ereignis W „es wird nicht noch einmal derselbe Zustand gezogen“ tritt im Zustand i mit der Wahrscheinlichkeit

$$P(W) = 1 - a_{i,i} \quad (3.57)$$

auf, wobei $a_{i,i}$ das entsprechende Element auf der Hauptdiagonalen der Zustandsübergangsmatrix \mathbf{A} bezeichnet.

Da die zu erwartende Aufenthaltsdauer in einem Zustand ein Wartezeitproblem darstellt, bei dem auf den ersten Eintritt des Ereignisses W gewartet wird, gehorcht die Anzahl der notwendigen Versuche einer geometrischen Verteilung [Geo04]. Der Erwartungswert der Anzahl an Zeitschritten Y , während denen in Zustand i verblieben

wird, ergibt sich aus dem Erwartungswert der geometrischen Verteilung.

$$E\{Y_i\} = \frac{a_{i,i}}{1 - a_{i,i}} \quad (3.58)$$

Da nun sowohl die Abfolge der Zustände als auch die erwarteten Aufenthaltsdauern in den einzelnen Zuständen für ein gegebenes Modell bekannt sind, kann ein *typischer Pfad* s' durch das Modell angegeben werden.

$$s' = (\underbrace{s_1, \dots, s_1}_{Y_1}, \underbrace{s_2, \dots, s_2}_{Y_2}, \dots, \underbrace{s_{N-1}, \dots, s_{N-1}}_{Y_{N-1}}, s_N) \quad (3.59)$$

Die zu erwartende Anzahl von Schritten $Y_{i,j}$, um vom Zustand i in Zustand j zu kommen, berechnet sich aus der Summe der einzelnen Aufenthaltsdauern.

$$E\{Y_{i,j}\} = \sum_{k=i}^{j-1} E\{Y_k\} \quad (3.60)$$

Diese Information kann benutzt werden, um eine praktikable *Zeitfenstergröße* T zu bestimmen, die gegen das extrahierte Modell getestet wird. Wird beispielsweise ein Modell zwischen dem dritten und vierten Zustand zerschnitten und das erste Teilmodell zur Manövererkennung genutzt, dann repräsentiert das aus den ersten drei Zuständen bestehende extrahierte Modell in den Trainingsdaten ein Zeitfenster von $Y_{1,4}$ Schritten. Die Zeitfenstergröße T ist ein Design-Parameter und muss nicht exakt mit diesem Erwartungswert übereinstimmen – allerdings ist er zumindest ein guter Orientierungspunkt.

Wird die Zeitdiskretisierung Δt berücksichtigt, kann von der in Zeitschritten gemessenen Dauer auf eine Dauer in Sekunden übergegangen werden. Dies ist für eine Aussage des zu erwarteten *Erkennungszeitpunktes* t_e wichtig. Im Beispiel wäre zu erwarten, dass das entsprechende Manöver

$$\Delta t_e = E\{Y_{1,4}\} \Delta t \quad (3.61)$$

Sekunden nach Manöverbeginn erkannt wird – dies ist der Zeitpunkt, an dem das extrahierte Modell bestmöglich passt.

3.6 Klassifikationskriterien

Die gängigsten Kriterien zur Lösung des Evaluierungsproblems und damit zur Klassifikation sind die Produktionswahrscheinlichkeit $P(\mathbf{O} | \lambda)$ bzw. die optimale Produk-

tionswahrscheinlichkeit $P(\mathbf{O}, \mathbf{s}^* | \lambda)$, die sich auf den am besten passenden Pfad \mathbf{s}^* durch das Modell beschränkt.

In Abschnitt 3.4.3 wurde gezeigt, wie die Produktionswahrscheinlichkeiten sich aufgrund einer Skalierung von kontinuierlichen Merkmalen und der damit verbundenen Modifikation der Dichteverteilungen verändern. Dieses Phänomen ist nicht auf skalierende Transformationen beschränkt. Vielmehr gilt allgemein, dass der Verlauf der Dichtefunktionen der Emissionen einzelner Zustände sowohl den Wert der Produktionswahrscheinlichkeit als auch den Dekodierungsprozess stark beeinflusst. Dies kann zuweilen zu unerwarteten Ergebnissen führen, insbesondere dann, wenn die Dichteverteilungen einzelner Zustände nicht nur unterschiedliche Erwartungswerte, sondern insgesamt stark unterschiedliche Verläufe haben. Im Falle der Emissionsmodellierung mit Normalverteilungen beispielsweise äußert sich dies durch große Unterschiede in den jeweiligen Varianzen.

Dieser Effekt soll im Verlauf des Kapitels näher untersucht werden. Dazu wird zunächst ein synthetisches Signal mit einem doppelt rampenförmigen Verlauf als HMM modelliert (Abschnitt 3.6.1). Im Anschluss wird versucht, ein passendes Signal der doppelten Rampe in einem Signalverlauf zu lokalisieren. Der Standardansatz der Auswertung der optimalen Produktionswahrscheinlichkeit führt allerdings nicht zum Ziel. Dieser Umstand wird durch Dekodierung an verschiedenen Stellen in Signalverlauf näher analysiert (Abschnitt 3.6.2). Da sich herausstellt, dass der optimale Pfad das Modell nicht in Gänze durchläuft, wird die Auswertung der optimalen Produktionswahrscheinlichkeit umgestellt. Die modifizierte Auswertung garantiert einen Start im ersten Zustand und ein Ende im letzten Zustand (Abschnitt 3.6.3). Dadurch lässt sich ein leicht verbessertes Ergebnis erzielen, zur Lokalisierung des Musters im Signalverlauf ist dieser Ansatz jedoch noch immer nicht ausreichend. Erst das Einführen eines neuen Klassifikationskriteriums, das eine *typische* Produktionswahrscheinlichkeit beschreibt, liefert einen verlässlichen und robusten Klassifikator für das Beispielsignal (Abschnitt 3.6.4) sowie für Manöverklassifikation im weiteren Verlauf der vorliegenden Arbeit.

3.6.1 Modellierung eines Beispielsignals

Als synthetisches Beispiel soll ein leicht verrauschtes doppelt rampenförmiges Signal als HMM mit normalverteilten Emissionen modelliert werden, siehe Abb. 3.6. Innerhalb von 100 Zeitschritten erfolgt ein Anstieg vom Wert 0 auf den Wert 10. Auf diesem Niveau verbleibt das Signal 700 Zeitschritte, bevor es innerhalb von 100 Zeitschritten wieder zurück auf den Wert 0 absinkt.

Für die Repräsentation der doppelten Rampe soll eine Markov-Kette mit drei

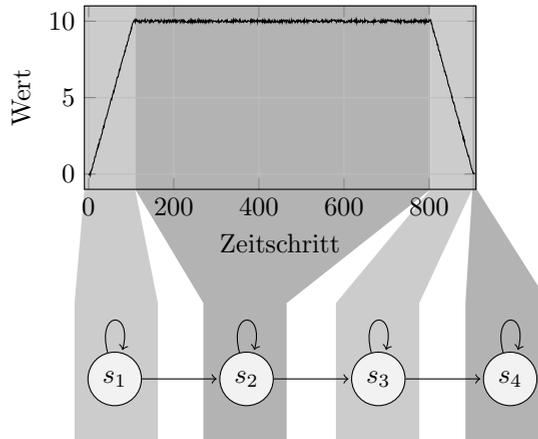


Abbildung 3.6: Modellierung eines leicht verrauschten doppelt rampenförmigen Signals mit einer Markov-Kette. Der erste Zustand beschreibt den Anstieg, der zweite das Verweilen beim Wert 10, und der dritte den Abstieg. Ein vierter Zustand soll sicherstellen, am Ende wieder beim Wert 0 anzukommen.

Zuständen genutzt werden. Eine naheliegende Segmentierung ist die Nutzung je eines Zustandes für den Anstieg, das Plateau und den Abstieg.¹² Ein vierter Zustand repräsentiert den Endzustand der Kette. Die Übergangsmatrix für Zustandsübergänge zwischen den vier Zuständen des linearen Modells ist wie beschrieben nur auf der Hauptdiagonalen und ersten oberen Nebendiagonalen besetzt, und ergibt sich anschaulich zu

$$\mathbf{A} = \begin{bmatrix} \frac{99}{100} & \frac{1}{100} & 0 & 0 \\ 0 & \frac{699}{700} & \frac{1}{700} & 0 \\ 0 & 0 & \frac{99}{100} & \frac{1}{100} \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

Die Erwartungswerte der Emissionen bei Auf- und Abstieg liegen jeweils in der Mitte der Rampe beim Wert 5. Die Varianzen müssen in diesem Fall die Werte aus dem Rampenverlauf abdecken und sind deshalb recht hoch. Auf dem Plateau ergibt sich ein Erwartungswert von 10 sowie nur eine kleine, durch das Rauschen verursachte

¹²Durch die Erzeugung von Signalverläufen mit leicht unterschiedlichen Niveaus und Anstiegsdauern kann an diesem Beispiel überprüft werden, ob ein trainiertes Modell eine ähnliche Segmentierung erzeugt. Für den in dieser Arbeit genutzten Trainingsalgorithmus wurde dies validiert.

Varianz. Der Abschlusszustand soll dafür Sorge tragen, dass auch die absteigende Rampe in Gänze durchlaufen wird und wird deshalb mit einem Erwartungswert von 0 und kleiner Varianz angegeben. Die Anfangswahrscheinlichkeiten werden gleichmäßig auf den Zuständen (außer dem Endzustand) verteilt. Bei Annahme von Varianzen passend zur Darstellung in Abb. 3.6 ergeben sich die übrigen Parameter des HMM zu

$$\begin{aligned}
 B_1 &\sim \mathcal{N}(b_1; 5, 8) & B_2 &\sim \mathcal{N}(b_2; 10, 10^{-1}) \\
 B_3 &\sim \mathcal{N}(b_3; 5, 8) & B_4 &\sim \mathcal{N}(b_4; 0, 10^{-1}) \\
 \pi &= \left(\frac{1}{3}, \frac{1}{3}, \frac{1}{3}, 0 \right).
 \end{aligned}$$

3.6.2 Klassifikation über die optimale Produktionswahrscheinlichkeit

Abb. 3.7 zeigt die fortlaufende Auswertung der logarithmierten optimalen Produktionswahrscheinlichkeit eines Signals.¹³ Das gepufferte Zeitfenster orientiert sich an der zu erwartenden Signallänge und hat beim gegebenen Modell einen Umfang von 900 Zeitschritten. Während der ersten 900 Zeitschritte wird lediglich ein Ringpuffer gefüllt und es erfolgt noch keine Auswertung der optimalen Produktionswahrscheinlichkeit. Danach wird der jeweils errechnete Wert über dem Zeitschritt aufgetragen.

Das Eingangssignal, in dem das Rampenmuster erkannt werden soll, besteht aus einer verrauschten Nulllinie, in der die Rampe zwischen den Zeitschritten 1000 und 1900 eingebettet ist. Die Erwartungshaltung an einen Klassifikator für eine vollständige Rampe ist gepunktet eingezeichnet. Am besten sollte das Modell am Ende der Rampe bei Zeitschritt 1900 passen. Aufgrund der stochastischen Natur von HMMs und der normalverteilten Emissionsmodellierung ist zu erwarten, dass das Modell auch in einem Bereich um diesen Zeitschritt herum größere Zugehörigkeitswerte liefert, allerdings mit deutlichem Abfall in beide Richtungen.

Der Verlauf der optimalen Produktionswahrscheinlichkeit kann dieser Erwartung in keinsten Weise gerecht werden. Es ergeben sich die höchsten Zugehörigkeitswerte für die gepufferte Nulllinie am Anfang und am Ende. Innerhalb der Rampe liefert das Modell zwar mit zeitlichem Fortschritt immer höhere Werte, eine Detektion

¹³Der Verlauf der Produktionswahrscheinlichkeit ist ähnlich. Da im vorliegenden Abschnitt Zustandsabfolgen näher untersucht werden und die optimale Produktionswahrscheinlichkeit direkt mit einem einzelnen Pfad durch das Modell korrespondiert, ist es anschaulicher, die Auswirkungen unterschiedlicher Varianzen an letzterer darzustellen.

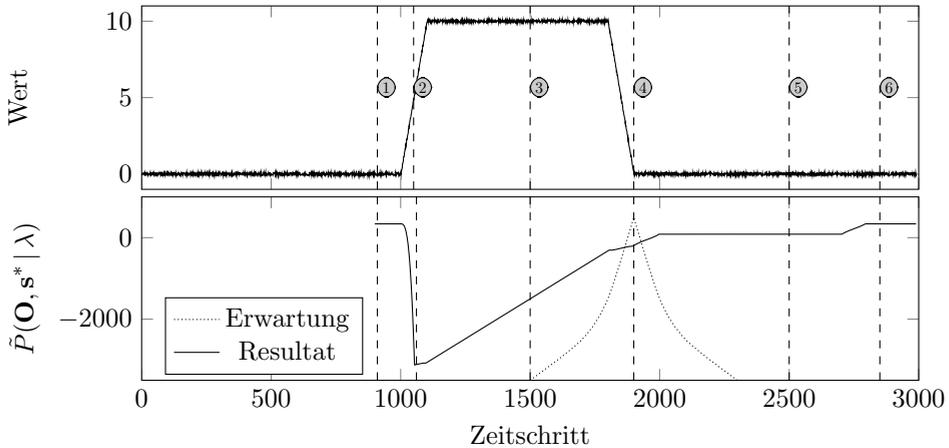


Abbildung 3.7: Optimale Produktionswahrscheinlichkeit eines Zeifensters von 900 Zeitschritten. Zu den markierten Zeitpunkten 1 – 6 wird der optimale Pfad untersucht.

der Rampe selbst über eine Schwellwertbildung auf diesem Signal ist jedoch nicht möglich.

Wie bereits erwähnt haben HMMs die angenehme Eigenschaft, dass nicht nur die Modellparameter selbst, sondern auch die Klassifikationsausgaben nachvollziehbar sind. Zu diesem Zweck wurde an den sechs in Abb. 3.7 markierten Zeitschritten eine Dekodierung durchgeführt und die Zustandsfolge des besten Pfades analysiert.

1. Zu Beginn des Signals besteht der Puffer aus einer verrauschten Nulllinie. Der beste Pfad aus verborgenen Zuständen s_i ergibt sich zu $\mathbf{s}_1^* = (s_3, s_4, s_4, \dots, s_4)$. Die verrauschte Nulllinie wird durch den Zustand 4 am besten wiedergegeben. Aufgrund der Startwahrscheinlichkeiten ist ein Beginn in Zustand 4 jedoch nicht möglich, der beste Pfad startet deshalb in Zustand 3 und geht direkt in Zustand 4 weiter. Eine lange Aufenthaltsdauer in einem Zustand, dessen Emission eine kleine Varianz besitzt, kann eine hohe Produktionswahrscheinlichkeit bewirken, auch wenn das Signalfenster eigentlich nicht zum Modellverlauf insgesamt passt.
2. Sobald das Signal in den Anstieg geht, ist Zustand 4 nicht mehr als Endzustand plausibel. Der beste Pfad ergibt sich zu $\mathbf{s}_2^* = (s_1, s_1, \dots, s_1)$ - das Modell befindet sich also während des gesamten Zeitfensters im ersten Zustand.¹⁴ Die Produktionswahrscheinlichkeit bricht ein, da dieser Zustand eine hohe Varianz

¹⁴Aus Symmetriegründen liefert Zustand 3 die selben Werte.

besitzt und damit tendentiell kleinere Werte der Wahrscheinlichkeitsdichtefunktion liefert.

- Der dritte Zeitpunkt befindet sich nach dem Anstieg auf dem Plateau zum Zeitpunkt 1500. Das gepufferte Zeitfenster der Länge 900 beinhaltet in den ersten 400 Einträgen die verrauschte Nulllinie, dann kommt der Anstieg der Länge 100 sowie 400 Elemente auf dem Plateau. Das Plateau wird am besten durch Zustand 2 beschrieben. Da kein Rückschritt im Modell möglich ist, muss die Nulllinie sowie der Anstieg durch Zustand 1 repräsentiert werden. Der beste Pfad lautet in der Tat¹⁵

$$\mathbf{s}_3^* = \left(\underbrace{s_1, s_1, \dots, s_1}_{494 \text{ El.}}, \underbrace{s_2, s_2, \dots, s_2}_{406 \text{ El.}} \right)$$

Der ansteigende Verlauf in der Umgebung um diesen Zeitpunkt wird durch eine Verschiebung des Pfades hin zu Zustand 2 verursacht.

- An diesem Punkt sollte das Modell ideal passen. In der Tat wird das Signal durch den besten Pfad intuitiv richtig segmentiert.

$$\mathbf{s}_4^* = \left(\underbrace{s_1, s_1, \dots, s_1}_{94 \text{ El.}}, \underbrace{s_2, s_2, \dots, s_2}_{714 \text{ El.}}, \underbrace{s_3, s_3, \dots, s_3}_{85 \text{ El.}}, \underbrace{s_4, s_4, \dots, s_4}_{7 \text{ El.}} \right)$$

Trotzdem ist die resultierende Produktionswahrscheinlichkeit kleiner als zu den Zeitpunkten 1, 5 und 6, da insgesamt mehr Zeit in den „unsicheren“ Zuständen 1 und 3 verbracht wurde.

- Im Bereich um Zeitpunkt 5 herum liegt der erste Teil des Zeitfensters in Zustand 2 auf dem Plateau, woran sich der Abstieg in Zustand 3 und die Nulllinie mit Zustand 4 anschließt. Die konkrete Zustandsfolge ergibt sich in diesem Punkt zu

$$\mathbf{s}_5^* = \left(\underbrace{s_2, s_2, \dots, s_2}_{208 \text{ El.}}, \underbrace{s_3, s_3, \dots, s_3}_{85 \text{ El.}}, \underbrace{s_4, s_4, \dots, s_4}_{607 \text{ El.}} \right).$$

- Die Daten in Zeitpunkt 6 entsprechen denen in Zeitpunkt 1.

Es zeigt sich, dass die Segmentierung zwar intuitiv richtig funktioniert, jedoch die Produktionswahrscheinlichkeit entscheidend davon profitiert, wenn die Verweildauer in einem „sicheren“ Zustand länger wird. Die Extremwerte der optimalen Produktionswahrscheinlichkeit sind zu den Zeitpunkten 1 und 6 aufgetreten. In diesen Fällen

¹⁵Kleine Verschiebungen sind vor allem dem Rauschen geschuldet.

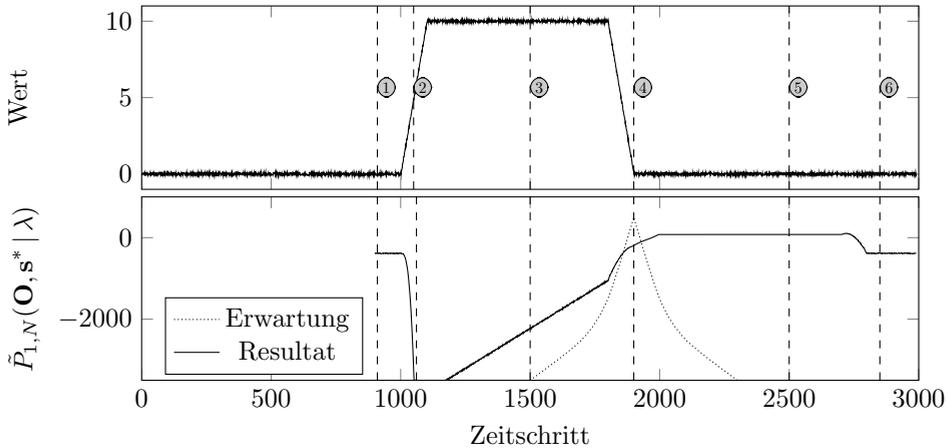


Abbildung 3.8: Optimale Produktionswahrscheinlichkeit eines Zeitfensters von 900 Zeitschritten. Der Pfad startet im ersten Zustand und endet im letzten.

wird jedoch das Zeitfenster fast ausschließlich mit dem letzten Zustand repräsentiert. Das Modell wird nicht in seiner Gesamtheit durchlaufen.

3.6.3 Festlegung von Start- und Endzustand

Um zu garantieren, dass das Modell vollständig durchlaufen wird, müssen Anfangs- und Endzustand vorgegeben werden. Zur Vorgabe des Anfangszustandes werden die Startwahrscheinlichkeiten angepasst.

$$\pi = (1, 0, 0, 0) \quad (3.62)$$

Zur Festlegung des Endzustandes wird beim Rekursionsabschluss des Algorithmus zur optimalen Produktionswahrscheinlichkeit eine Beschränkung auf den letzten Zustand vorgenommen, anstatt das Maximum auszuwählen.

$$P_{1,N}(\mathbf{O}, \mathbf{s}^* | \lambda) = P(\mathbf{O}, \mathbf{s}^* | \lambda, s_1 = S_1, s_T = S_N) = \delta_T(N) \quad (3.63)$$

In Abb. 3.8 ist die mit diesen Änderungen ausgewertete optimale Produktionswahrscheinlichkeit dargestellt. Im Vergleich zu Abb. 3.7 bewirkt die Festlegung von Anfangs- und Endzustand und das damit verbundene Erzwingen des vollständigen

Durchlaufs des Modells zumindest, dass das Maximum der optimalen Produktionswahrscheinlichkeit nicht mehr bei einer reinen Nulllinie (Zeitpunkte 1 und 6), sondern im Nachgang zum Muster (um Zeitpunkt 5 herum) auftritt. Trotzdem ist der Wert für eine Klassifikation über Schwellwertbildung nicht ausreichend.

Zur Analyse sei beispielhaft der unter den gegebenen Restriktionen optimale Pfad zum Zeitpunkt 5 herausgegriffen:

$$\mathbf{s}_{r,5}^* = (s_1, \underbrace{s_2, s_2, \dots, s_2}_{207 \text{ El.}}, \underbrace{s_3, s_3, \dots, s_3}_{85 \text{ El.}}, \underbrace{s_4, s_4, \dots, s_4}_{607 \text{ El.}})$$

Aus dem ersten Zustand wird direkt weitergesprungen. Noch deutlicher wird dies bei gepufferten reinen Nulllinien in den Zuständen 1 und 6.

$$\mathbf{s}_{r,6}^* = (s_1, s_2, s_3, \underbrace{s_4, s_4, \dots, s_4}_{897 \text{ El.}})$$

In diesem Fall wird jeweils direkt in den nächsten Zustand weitergesprungen und fast der gesamte Signalpuffer auf den Endzustand segmentiert. Das Klassifikationsergebnis erzeugt einen recht guten Wert, obwohl der gepufferte Signalverlauf die Gesamtheit des Modells nicht repräsentiert. Offensichtlich können einzelne Zustände oder sogar Zustandsfolgen praktisch übersprungen werden, ohne dass dies signifikante negative Auswirkungen bezüglich des Klassifikationsergebnisses bewirkt. Dieser Umstand relativiert die zunächst hart anmutende Beschränkung auf lineare anstatt allgemeinere links-rechts-Modelle in Abschnitt 3.5.1. Es ist eine Auswirkung der geometrisch verteilten Verweildauern in den einzelnen Zuständen einer Markov-Kette. Abb. 3.9a zeigt ein Beispiel einer geometrischen Verteilung mit einer Erfolgswahrscheinlichkeit von 0,01. Wie man sieht, konzentriert sich ein hoher Anteil der Wahrscheinlichkeitsmasse bei niedrigen Verweildauern, die entsprechend attraktiv für den Segmentierungsprozess werden.

Die Notwendigkeit, alle Zustände eines linearen Modells durchlaufen zu müssen, wirkt sich bei der Auswertung der Klassifikationsergebnisse nicht negativ aus. Im Gegenteil kann die Möglichkeit eines zu schnellen Überspringens unerwünschte Klassifikationsergebnisse bewirken.

Ein allgemeiner Lösungsansatz wäre die Ersetzung der zugrunde liegenden Markov-Kette mit einer Semi-Markov-Kette. Im Gegensatz zu einer Markov-Kette, bei der in jedem Zeitschritt anhand des aktuellen Zustandes und der Matrix der Übergangswahrscheinlichkeiten ein neuer Zustand gezogen wird, wird bei Semi-Markov-Ketten bei Eintritt in einen Zustand eine Verweildauer anhand einer beliebigen Verteilung gezogen. Mit dieser Methode können demnach durch eine entsprechende Wahl der

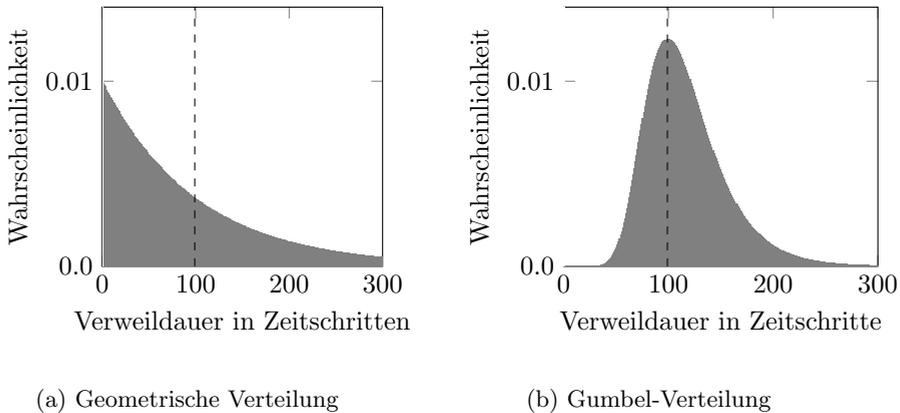


Abbildung 3.9: Links: Geometrische Verteilung mit einem Erwartungswert von 99. Eine hohe Wahrscheinlichkeitsmasse konzentriert sich auf niedrigen Verweildauern. Rechts: Gumbel-Verteilung mit einem Ortsparameter von 99. Sehr kleine Verweildauern treten nur noch extrem selten auf.

Verteilung u.a. minimale oder maximale Verweildauern garantiert und ein direktes Weiterlaufen in einem linearen Modell verhindert werden. Ein Beispiel für eine Verteilung von Verweildauern wäre die in Abb. 3.9b dargestellte Gumbel-Verteilung.¹⁶ Hier soll lediglich angemerkt werden, dass sich die Komplexität im Umgang mit den Modellen durch die Aufweichung der Markov-Eigenschaft stark erhöht. Für einen Einstieg in die Theorie der Hidden-Semi-Markov-Modelle sei auf [Mur02a; Mur02b] verwiesen. Im Rahmen dieser Arbeit soll mit der Betrachtung von typischen Produktionswahrscheinlichkeiten ein spezialisierterer und recheneffizienterer Ansatz verfolgt werden.

3.6.4 Typische Produktionswahrscheinlichkeit

In Abschnitt 3.5.3 wurde gezeigt, wie für lineare Modelle ein typischer Pfad \mathbf{s}' angegeben werden kann. Mit *typischer Produktionswahrscheinlichkeit* $P(\mathbf{O}, \mathbf{s}' | \lambda)$ sei im Folgenden die Produktionswahrscheinlichkeit entlang des typischen Pfades

¹⁶Zufällige Zeitintervalle werden typischerweise mit einer Exponentialverteilung modelliert [Hen11]. Die Maximalwerte eines Satzes von exponential verteilten Samples folgen einer Gumbel-Verteilung [Gum41], was diese für die Ziehung von Verweildauern mit einem Hang zur Vermeidung kleiner Werte geeignet erscheinen lässt.

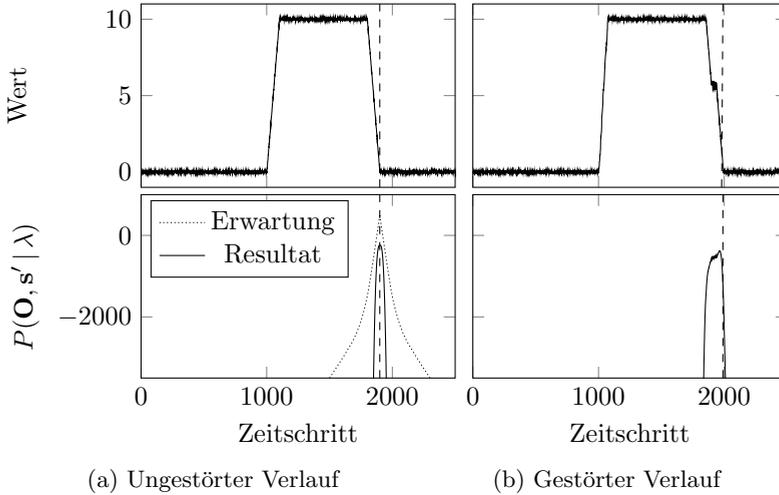


Abbildung 3.10: Produktionswahrscheinlichkeit entlang des typischen Pfades. Der Wert lässt sich auch dann noch zur Klassifikation nutzen, wenn das Signal die Segmentierung des typischen Pfades nicht mehr exakt widerspiegelt.

bezeichnet. Diese berechnet sich zu

$$P(\mathbf{O}, \mathbf{s}' | \lambda) = \prod_{t=1}^T a_{s'_{t-1}, s'_t} b_{s'_t}(O_t). \quad (3.64)$$

Abb. 3.10 zeigt die entsprechende Auswertung von Beispielmodell und Beobachtungsfolge. Zur Erkennung der eingebetteten Rampe erhält man nun wie erwartet eine eindeutige Spitze im Zugehörigkeitssignal, die für eine Klassifikation verwendet werden kann. Allerdings fallen nun durch die Vorgabe des Pfades die Freiheitsgrade der Segmentierung in der Auswertung weg. Bei einem Signal, das nicht mehr mit der Segmentierung des ursprünglichen Pfades übereinstimmt, sind Einbußen zu erwarten. Das Signal in Abb. 3.10b ist leicht verfälscht: Der Anstieg erfolgt steiler, das Plateau ist länger, und der Abstieg erfolgt über eine kleine Stufe. Obgleich die typische Produktionswahrscheinlichkeit in der Tat keinen so steilen Ausschlag erzeugt, ist das Ergebnis immer noch zur Detektion der Rampe verwendbar. Durch die probabilistische Natur der Emissionsmodellierung kann das HMM auch mit einer gegebenen, weniger guten Segmentierung umgehen.

Die typische Produktionswahrscheinlichkeit ist dann ein gutes Klassifikationssignal,

wenn die zu erkennenden Beobachtungsfolgen nicht eklatant von der Segmentierung des typischen Pfades abweichen. Dies ist bei Modellen für einen Manöverbeginn, der lediglich die ersten 1 – 3 Sekunden eines Manövers repräsentiert, gegeben.¹⁷ Die typische Produktionswahrscheinlichkeit ist damit ein geeignetes Maß zur Detektion und Klassifikation eines Manöverbeginns und wird im Folgenden als Klassifikationskriterium herangezogen.

3.7 Merkmalsextraktion

Die Absichtserkennung soll mit Merkmalen auskommen, von denen angenommen werden kann, dass sie in naher Zukunft in Fahrzeugen mit Assistenzsystemen verfügbar sind. Dazu zählen neben Informationen über die aktuelle Dynamik des Fahrzeugs (z. B. Geschwindigkeit und Gierrate) auch Signale, über die der Fahrer direkt auf die Fahrdynamik einwirkt. Dies sind vor allem Lenk- und Pedalbewegungen und deren Auswirkungen (z. B. Lenkwinkel oder Bremsdruck). Im Versuchsträger konnten diese Informationen vom CAN-Bus abgegriffen werden.

Darüber hinaus wird davon ausgegangen, dass digitale Straßenkarten, wie sie beispielsweise in Navigationssystemen Verwendung finden, verfügbar sind. Eine Schätzung der lateralen Position des Fahrzeugs im Fahrstreifen wird ebenfalls benutzt.

3.7.1 Digitale Straßenkarten

Aus digitalen Straßenkarten können kontinuierliche Informationen und Statusinformationen extrahiert werden. Zu den Statusinformationen zählt z. B., auf welcher Straßekategorie sich das Fahrzeug gerade befindet und wie viele Fahrstreifen es in Fahrtrichtung gibt. Diese Informationen werden für diese Arbeit in einer der Klassifikation vorgeschalteten Plausibilitätsuntersuchung genutzt, um die Modelle auszuwählen, die überhaupt getestet werden sollen.

Zusätzlich wird die Entfernung zur nächsten Kreuzung, an der ein Abbiegen nach links bzw. rechts möglich ist, als Merkmal extrahiert. Hier wird keine Beschränkung auf erlaubte Abbiegemanöver vorgenommen. Fehlverhalten durch unerlaubtes Abbiegen ist eine seltene Fahrsituation mit besonderer Gefährdung, die nicht unterschätzt werden soll.

¹⁷Dies muss nicht unbedingt für längere Modelle gelten, die z. B. ein gesamtes Manöver repräsentieren. In diesen Fällen wäre zu untersuchen, ob der Weg über Semi-Markov-Modell nicht zielführender wäre.

Als weitere Kontextinformation kann die Straßenkrümmung aus Navigationskarten erhalten werden. Basierend auf der Lenkübersetzung des Fahrzeugs und der aktuellen Straßenkrümmung kann darüber hinaus der Radlenkwinkel abweichend zu demjenigen Radlenkwinkel, der für die Fahrstreifenhaltung benötigt wird, erhalten werden.

3.7.2 Laterale Position des Fahrzeugs im Fahrstreifen

Ein wichtiges Merkmal für die Erkennung von Fahrstreifenwechseln stellt die laterale Position des Fahrzeugs im Fahrstreifen dar. Diese wird aus einer bildbasierten Fahrstreifenenerkennung mit einer gegenüber dem Fahrzeug kalibrierten Kamera gewonnen.

Die Fahrstreifenenerkennung wurde im Kontext dieser Untersuchung im Rahmen einer Studienarbeit entwickelt [Vep09]. Der Fokus lag dabei nicht auf der Weitsicht des kommenden Fahrstreifenverlaufes, sondern in einer robusten und stabilen Erkennung des Fahrstreifens in unmittelbarer Umgebung des Fahrzeuges.

Aus der lateralen Position kann durch numerische Ableitung über das gesammte Zeitfenster ein hochwertiges Signal für die laterale Bewegung des Fahrzeuges im Fahrstreifen erhalten werden.

3.7.3 Auswahl der Merkmale

Die Signale von Fahrtrichtungsanzeiger, Beschränkungen der Verkehrsführung aus Karten und Ergebnisse einer Fahrzeugumfeldererkennung wurden bewusst nicht für die probabilistische Absichtserkennung genutzt. Der Status der Fahrtrichtungsanzeiger ist auf dem CAN-Bus verfügbar, stellt eine direkte Absichtserklärung des Fahrers an sein Umfeld dar und erscheint damit eigentlich prädestiniert für die Nutzung als Merkmal für die Absichtserkennung. Studien haben gezeigt, dass die Fahrtrichtungsanzeiger beispielsweise bei einem Fahrstreifenwechsel nur in unter 70% der Fälle, in denen sie eigentlich nötig wären, gesetzt werden - und dann oft zu spät [Hen10; Ols03]. Das allein wäre aber kein Grund, von ihrer Verwendung generell Abstand zu nehmen - ein Klassifikator könnte ihnen ein ihrer Aussagekraft entsprechendes Gewicht zuweisen, so wie es bei anderen Merkmalen auch der Fall ist. In der Tat wäre bei Nutzung der Information der Fahrtrichtungsanzeiger vermutlich eine Verbesserung der Erkennungsraten zu erwarten. Allerdings darf nicht aus den Augen verloren werden, dass die Ergebnisse der Absichtserkennung in einem nachfolgenden Schritt als Grundlage für eine Gefährlichkeitsbewertung einer Verkehrssituation dienen sollen. Gefährliche Situationen entstehen unter anderem dann, wenn die eigene Absicht z. B. mit Hilfe der Fahrtrichtungsanzeiger nicht oder gar

Tabelle 3.1: Untersuchte Merkmale und ihre Verwendung

Merkmale	Verwendung
Straßenkategorie	Plausibilitätsprüfung, Auswahl der Modelle
Anzahl der Fahrstreifen	
Nächste Abbiegemöglichkeit	
Laterale Bewegung im Fahrstreifen	Erkennung Fahrstreifenwechsel
Radlenkwinkel abweichend von Straßenkrümmung	Frühere Erkennung von Fahrstreifenwechseln
Lenkwinkel	Erkennung Abbiegemanöver, Aufbau der Trainingsdatenbank
Lenkwinkelgeschwindigkeit	Aufbau der Trainingsdatenbank
Fahrtrichtungsanzeiger	
Laterale Position im Fahrstreifen	Berechnung der lat. Bewegung
Straßenkrümmung	Kompensation des Radlenkwinkels
Geschwindigkeit	Nicht genutzt
Gierrate	
Gaspedalstellung	
Bremsdruck	

fehlerhaft dem Umfeld kommuniziert wurde. Bei Nutzung der Fahrtrichtungsanzeiger als Klassifikationsmerkmal bestünde die Gefahr, dass das System zwar statistisch bessere Ergebnisse liefert, aber gerade in den potentiell gefährlichen Situationen versagt.

Ähnliches gilt für die Ergebnisse von Systemen zur Erfassung und Verfolgung von dynamischen Objekten aus dem Umfeld des Fahrzeugs [Kam07; Wen08]. Auch hier ist zu erwarten, dass statistisch gesehen die Ergebnisse der Absichtserkennung verbessert würden, weil Objektkonstellationen bestimmte Manöver unplausibel machen. Das Übersehen von anderen Verkehrsteilnehmern ist jedoch eine häufige Unfallursache [Sta14]. Die erwartete scheinbare statistische Verbesserung wäre vor allem darin begründet, dass gefährliche Situationen und Unfälle seltene Ereignisse sind. Wenn andererseits beispielsweise ein mögliches Abbiegemanöver nach links aufgrund von Gegenverkehr von vornherein verworfen wird, vermindert das den Nutzen des Systems deutlich. Aus diesem Grund wird im Rahmen der Absichtserkennung auf die Nutzung von Objektinformationen aus dem Fahrzeugumfeld verzichtet.

Tabelle 3.1 gibt eine Übersicht über die untersuchten Merkmale und ihre Verwendung (oder nicht-Verwendung) im Verlauf dieser Arbeit. Die einzelnen Ansätze werden in den folgenden Kapiteln an passender Stelle näher erläutert.

Die aus der Navigationskarte abgeleiteten Merkmale Straßenkategorie, Anzahl der Fahrstreifen und Distanz bis zur nächsten Abbiegemöglichkeit werden zur Auswahl der Modelle, die aktuell berücksichtigt werden sollen, genutzt. Die Erkennung von Fahrstreifenwechseln stützt sich auf die laterale Bewegung des Fahrzeugs im Fahrstreifen. Bei Untersuchungen bezüglich eines früheren Erkennungszeitpunktes für Fahrstreifenwechselmanöver wird zusätzlich der Radlenkwinkel genutzt, der um den zum Halten des Fahrstreifens benötigten Radlenkwinkel kompensiert wurde. Abbiegemanöver werden mit dem Lenkwinkel als Merkmal erkannt.

Lenkwinkel, Lenkwinkelgeschwindigkeit und Fahrtrichtungsanzeiger werden als Hilfsmittel beim Aufbau der Trainingsdatenbank verwendet. Die laterale Position des Fahrzeugs im Fahrstreifen wird nicht als separates Merkmal, sondern lediglich zur numerischen Berechnung der lateralen Bewegung genutzt. Die Straßenkrümmung wird ebenfalls nicht als Merkmal verwendet, sondern nur zur Kompensation des Radlenkwinkels. Fahrzeuggeschwindigkeit, Gierrate, Gaspedalstellung und Bremsdruck werden nicht verwendet.

Diese Auswahl der Merkmale ist das Ergebnis umfangreicher Untersuchungen. So hat sich z. B. herausgestellt, dass Gaspedalstellung und Bremsdruck für sich genommen keine aussagekräftigen Merkmale sind. Bei Fahrstreifenwechseln kommt es beispielsweise vor, dass der Fahrer das Fahrzeug in den Zielstreifen hinein beschleunigt oder hinein bremst. Ebenso gilt bei Abbiegevorgängen, dass in der Vorbereitung sowohl beschleunigt als auch gebremst werden kann, beispielsweise abhängig davon, ob die Straße bergauf oder bergab führt, oder wie der Umgebungsverkehr sich verhält. Wie man in den folgenden Kapiteln sehen wird, können jedoch mit der restriktiven Auswahl der Merkmale bereits gute Ergebnisse erzielt werden. Die Untersuchung von komplexeren Merkmalen (z. B. ein kombiniertes Merkmal aus Gaspedalstellung, Bremsdruck und Höhenprofil der Straße) kann Thema für zukünftige Untersuchungen werden.

3.8 Training der Hidden-Markov-Modelle

3.8.1 Trainingsdatenbank

Für das Training der HMMs ist zunächst die Beschaffung von Beispieldaten nötig. Dazu wurden Testfahrten im normalen Straßenverkehr aufgenommen und die zu erkennenden Manöver in diesen identifiziert. Das Ergebnis dieses Arbeitsschrittes ist eine Datenbank, in der die Manöver jeweils mit Zeitstempel des Manöverstarts und des Manöverendes sowie einer manöverspezifischen Kennung aufgeführt wurden.

Zusätzlich wurde der Name des Testfahrers notiert.

Die Erzeugung dieser annotierten Datenbank aus Testfahrten erfolgte in zwei Phasen. Zunächst wurden die Testfahrten mit einem einfachen Algorithmus auf mögliche Manöver untersucht. Der Algorithmus basiert auf der Vorstellung, dass Manöver sich im Gegensatz zu normaler Fahrstreifenhaltung durch unetigere Lenk- und Pedalbewegungen sowie durch Setzen der Fahrtrichtungsanzeiger auszeichnen. Alle Abschnitte der Testfahrten, in denen die Gradienten dieser Signale einen Schwellwert überschreiten, wurden automatisch als Kandidaten für Manöver vorgeschlagen. Die Schwellwerte wurden dabei so gewählt, dass möglichst wenige Manöver unerkannt blieben, bei Inkaufnahme einer hohen Anzahl von Falschalarmen. Die gefundenen Kandidaten wurden dann manuell überprüft und bestätigt bzw. verworfen. Wenn gleich immer noch aufwändig, ermöglicht es diese Methode, große Mengen von Daten effizient zu bearbeiten.

Da diese Datenbank für Training und später auch für die Systemevaluierung verwendet wird, ist ihre Korrektheit essentiell. Deshalb muss das Ergebnis der halbautomatischen Manöverextraktion in einer zweiten Phase manuell überprüft werden, indem sämtliche Testfahrten und die zugehörige Einordnung in Manöver gesichtet und bestätigt wird. Dazu konnten Videos der Testfahrten im Schnelldurchlauf mit eingblendeter Annotierung betrachtet werden.

Beim nachträglichen Auswerten der während einer freien Testfahrt aufgenommenen Daten ist es nicht möglich, den Zeitpunkt, an dem der Fahrer die Absicht gefasst hat, ein Manöver einzuleiten, exakt zu bestimmen. Dies wäre selbst dann, wenn man dem Fahrer die zu fahrenden Manöver vorgibt (siehe z. B. [ZQL⁺14]) oder den Fahrer bevorstehende Manöver ansagen lässt, nur begrenzt möglich. In beiden Fällen wären die Daten mit dem zusätzlichen Makel behaftet, dass der Fahrer sich bewusst ist, dass seine Fahrmanöver von Interesse sind. Dieses Wissen könnte die Messung verfälschen, da die Gefahr besteht, dass Fahrer sich kontrolliert fühlen und gezielt versuchen, „saubere“ Manöver zu fahren.

Bei einer Markierung der Daten für das nachfolgende Training von HMMs ist es aus methodischer Sicht weniger von Bedeutung, dass der exakte Zeitpunkt der Willensbildung des Fahrers erfasst wurde. Vielmehr ist es wichtig, dass die Beispiele in sich konsistent markiert sind. Für die Festlegung der Start- und Endzeitpunkte von Manövern wurde deshalb ein Kriterium festgesetzt, das Konsistenz und Reproduzierbarkeit möglichst gut gewährleisten sollen. Im konkreten Fall wurde betrachtet, wann Lenkwinkel bzw. Lenkwinkelgeschwindigkeit sich sichtbar in der Weise ändern, dass das Fahrmanöver ein- und wieder ausgeleitet wird. Auf diese Weise ist ein Manöverbeginn i.Allg. wesentlich klarer sichtbar als beispielsweise bei der Betrachtung eines Kamerabildes aus dem Fahrzeug heraus. Bei manchen Manövern ist jedoch auch mit Lenkwinkelkriterium kaum ein exakter Manöverbeginn feststellbar, beispielsweise bei

einem Fahrstreifenwechsel bei gleichzeitiger Krümmungsänderung der Fahrbahn in entgegengesetzter Richtung. In diesem Fall waren Manöveranfang und -ende durch den Bearbeiter unter Berücksichtigung der lateralen Bewegung des Fahrzeuges im Fahrstreifen bestmöglich abzuschätzen.

Bei vielen lernenden Klassifikationsverfahren sollte eine möglich große Bandbreite an typischen und weniger typischen Beispieldaten im Training verwendet werden. Wenn jedoch aus einem HMM, das seine Segmentierung im Trainingprozess lernt, kürzere Teilmodelle extrahiert werden sollen, ist es wichtig, dass die Segmentierung im Training gut herausgearbeitet werden konnte. Es bietet sich damit an, tendenziell eher gut ausgeführte und erfasste Manöver für das Training zu verwenden. In dem für die Bewertung genutzten markierten Datensatz sind dementsprechend die tendenziell schwierigeren Fälle enthalten. Demnach ist zu erwarten, dass die Klassifikatorleistung tendenziell eher unterschätzt wird.

Durch die probabilistische Modellierung sowohl von Zustandsübergängen als auch von Emissionen können die resultierenden Modelle auch die weniger klar in den Daten sichtbare Manöver gut erfassen, wie in der Auswertung in Kapitel 3.9 gezeigt wird.

3.8.2 Erzeugung der Merkmalsvektoren

Dem Klassifikator stehen Merkmale zur Verfügung, die von unterschiedlichen Sensoren und mit verschiedenen Messfrequenzen und Totzeiten erfasst werden. In der Modellvorstellung wird jedoch davon ausgegangen, dass zu jedem Zeitpunkt ein vollständiger Merkmalsvektor beobachtet wird. Die Frequenzen der zur Verfügung stehenden Signale müssen also angeglichen werden. Um keine Information zu verlieren, orientiert sich diese Angleichung am Signal mit der höchsten Frequenz. In der vorliegenden Arbeit waren dies Signale vom CAN-Bus, die mit einer Wiederholrate von 10 ms vorlagen. Niederfrequente Signale werden einer durch lineare Interpolation angenäherten Aufwärtsabtastung [OSB04] unterzogen.

Da ein Zeitfenster konstanter Größe von Merkmalsvektoren vorgehalten werden muss, bietet sich als effiziente Datenstruktur ein Ringpuffer an. Die Länge des Ringpuffers richtet sich dabei nach der Anzahl der Beobachtungen, die nötig sind, um ein Zeitfenster der Größe entsprechend Abschnitt 3.5.3 abzudecken.

Beim Füllen des Ringpuffers können Totzeiteffekte berücksichtigt werden. Trifft eine Messung ein, von der bekannt ist, dass der Messzeitpunkt weiter in der Vergangenheit liegt, kann diese Messung direkt an die richtige Stelle im Puffer einsortiert werden.

Es kann deshalb ohne großen Mehraufwand immer die bestmögliche Kenntnis über die Messfolgen verwendet werden.

Sobald die Messungen vorliegen, können in einem Vorverarbeitungsschritt neue Merkmale aus den Messungen berechnet werden. Die Betrachtung eines in der Vergangenheit liegenden Zeitfensters ermöglicht es beispielsweise, den Messwertverlauf zunächst zu glätten und dann die Ableitung über zentrale finite Differenzen höherer Ordnung zu bestimmen. Diese Möglichkeiten fehlen bei Klassifikationsmethoden, die sich nicht auf ein vergangenes Zeitfenster, sondern nur auf die aktuellen Signale beziehen, wo nur einseitige Glättungs- und Differenzmethoden zur Verfügung stehen. Abgeleitete Signale können bei einer Klassifikation über Hidden-Markov-Modelle deshalb in einer hohen Qualität erzeugt werden. Ein in dieser Arbeit verwendetes Merkmal ist die laterale Bewegung des Fahrzeuges im Fahrstreifen, die durch eine zeitliche Differenzierung der lateralen Position gewonnen wird. Ebenso wird die Lenkwinkelgeschwindigkeit aus der Ableitung des Lenkwinkels berechnet, wodurch im genutzten Versuchsträger eine höhere Qualität als beim Signal der Lenkwinkelgeschwindigkeit vom CAN-Bus erreicht wurde.

3.8.3 Auswahl der Modellstrukturparameter

Da die Modelltopologie bereits auf lineare Modelle festgelegt wurde, bleibt als Strukturparameter lediglich die Anzahl der Zustände übrig. Einerseits muss die Anzahl der Zustände ausreichend sein, um dem Trainingsalgorithmus eine geeignete Segmentierung der Daten zu ermöglichen. Andererseits sollten bei einer limitierten Zahl an Trainingsdaten keine unnötigen Freiheitsgrade eingeführt werden, die die Parameteroptimierung erschweren.

Im Rahmen dieser Arbeit erfolgte die Festlegung der Anzahl der Modellzustände iterativ. Fällt bei näherer Betrachtung eines trainierten Modells auf, dass zwei aufeinanderfolgende Zustände sehr ähnliche Emissionsverteilungen haben, ist das ein Hinweis darauf, dass einer der beiden Zustände nicht benötigt wird. Andererseits können große Varianzen in sämtlichen Emissionen eines Zustandes ein Hinweis darauf sein, dass Freiheitsgrade im Segmentierungsprozess fehlen, um das Modell an die Daten anzupassen. Dies ist lediglich ein Hinweis, keine zwingende Schlussfolgerung. Es könnte beispielsweise auch sein, dass alle genutzten Merkmale einen Bereich im Modell nicht aussagekräftig beschreiben. In diesem Fall würde eine Erhöhung der Anzahl der Zustände keine positive Wirkung haben, sondern es sollte nach zusätzlichen Merkmalen gesucht werden.

Im Folgenden wurde für alle betrachteten Manöver mit einem linearen Hidden-Markov-Modell mit neun Zuständen angesetzt. Dieses Ausgangsmodell wurde dann

Tabelle 3.2: Anzahl der Manöver in der Datenbank für Fahrstreifenwechsel nach links und rechts (FSWL, FSWR) sowie Abbiegevorgänge (ABVL, ABVR)

Manöver	Gesamtanzahl	Training	Auswertung
FSWL	216	80	136
FSWR	223	80	143
ABVL	92	50	42
ABVR	107	50	57

nach Abschnitt 3.3.7 initial segmentiert und anschließend nach Abschnitt 3.3.6 trainiert.

3.9 Auswertung der Erkennungsleistung

3.9.1 Umfang der Analyse

Als Grundlage für die Auswertung dient die in Kapitel 3.8.1 beschriebene Datenbank mit markierten Manövern. Diese Datenbank hat einen Umfang von etwa 10 Stunden Autofahrt in verschiedenen Umgebungen. Die Fahrten decken den innerstädtischen Bereich, Wohn- und Industriegebiete, Vorstädte sowie Landstraßen und Autobahnen ab. Insgesamt waren 9 verschiedene männliche Fahrer beteiligt, von denen 8 keine Kenntnis darüber hatten, dass ihre Testfahrten im Hinblick auf eine Manövererkennung untersucht werden.¹⁸

Die Anzahlen der in der Datenbank enthaltenen markierten Manöver kann Tabelle 3.2 entnommen werden. Hierbei werden Fahrstreifenwechsel nach links bzw. rechts mit FSWL und FSWR, Abbiegevorgänge nach links und rechts mit ABVL und ABVR abgekürzt.

Von den in der Trainingsdatenbank enthaltenen Manövern wird eine Auswahl von tendentiell sauber ausgeführten und aufgenommenen Manövern zum Training der Modelle genutzt. Das bedeutet, dass die aufgenommenen Signale sauber vorlagen,

¹⁸Klanner hat in [Kla08] gezeigt, dass die Varianzen der Fahrmanöver einzelner Fahrer viel größer sind als die Varianzen zwischen mittleren Manöveraushführungen verschiedener Fahrer, was den Fokus bei der Generierung von Testdatenbanken eher hin zu einem großen Umfang als zur Beteiligung von vielen Fahrern verschiebt.

und es beispielsweise keine Aussetzer bei Fahrstreifenerkennung oder Positionierung in der digitalen Karte gab.

Bei Fahrstreifenwechsellvorgängen wurden jeweils 80 Manöver zum Training genutzt. Für die Auswertung bleiben damit 136 Manöver für Fahrstreifenwechsel nach links und 143 Manöver für Fahrstreifenwechsel nach rechts sowie der gesamte Zeitraum ohne das entsprechende Manöver übrig.

Für das Training von Abbiegevorgängen wurden jeweils 50 Manöver genutzt, die Auswertung erfolgt mit den übrigen 42 bzw. 57 für Abbiegevorgänge nach links und rechts.

3.9.2 Bewertung der Erkennungsleistung

Der Klassifikator zur Absichtserkennung besteht aus einem Satz von Einzelklassifikatoren für jedes Manöver. Jeder Einzelklassifikator soll das entsprechende Manöver sowohl gegenüber normalem Fahrstreifen-Folgeverhalten als auch gegenüber den anderen definierten Manövern abgrenzen. Es handelt sich damit um „one-versus-all“-Klassifikatoren.

Das Ergebnis eines Klassifikators gibt an, wie gut ein gepuffertes Zeitfenster zu einem erlernten Manöverbeginn passt. Mit diesem probabilistischen Ähnlichkeitsmaß kann direkt weitergearbeitet werden. Im Kontext eines vollständigen Assistenzsystems ist eine Entscheidungsfindung an dieser Stelle der Verarbeitungskette nicht notwendig.

Um eine quantitative Aussage über die Klassifikatorleistung zu treffen, ist eine binäre Aussage des Klassifikators, ob die jeweilige Klasse vorliegt oder nicht, dennoch hilfreich. Diese erhält man durch Schwellwertbildung auf dem Ähnlichkeitsmaß.

Die Leistung von binären Klassifikatoren wird in der Literatur oft mittels *Konfusionsmatrizen* quantitativ angegeben. Die durch Parametrisierung erreichbaren Kompromisse zwischen einer guten Erkennungsrate und einer niedrigen Falschalarmrate des Klassifikators können mit Hilfe von *Receiver Operating Characteristic* (ROC)-Kurven veranschaulicht werden. Beide Arten der Auswertung der Klassifikationsergebnisse werden im Folgenden beschrieben.

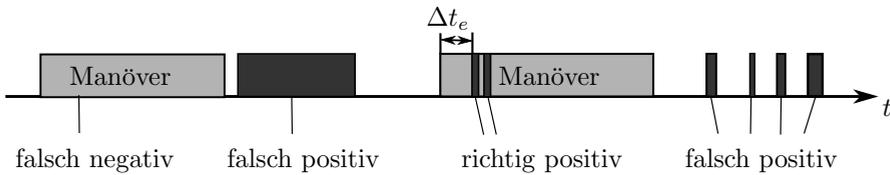


Abbildung 3.11: Darstellung von richtig und falsch positiven sowie falsch negativen Klassifikationsergebnissen auf einem Zeitstrahl. Die Dauer eines positiven Klassifikatorergebnisses ist dunkel gekennzeichnet. Die Dauer eines Manövers ist mit einer hellgrauen Box markiert.

3.9.2.1 Konfusionsmatrizen

In einer Konfusionsmatrix werden die Ergebnisse des Klassifikators einer Grundwahrheit gegenübergestellt. Die Grundwahrheit besteht im vorliegenden Fall aus den Einträgen in der Manöverdatenbank, die nicht während des Trainings verwendet wurden.

Dabei werden die Ergebnisse des Klassifikators in vier Fälle aufgeteilt:

Richtig positiv Ein Manöver liegt vor und wurde richtig klassifiziert.

Richtig negativ Ein Manöver liegt nicht vor und wurde vom Klassifikator auch nicht als Manöver angesehen.

Falsch positiv Ein Manöver liegt nicht vor, es wurde aber vom Klassifikator ein Manöver angezeigt.

Falsch negativ Ein Manöver liegt vor, es wurde vom Klassifikator aber nicht angezeigt.

In Abb. 3.11 wird schematisch ein Ausschnitt einer Testfahrt anhand eines Zeitstrahles analysiert. Eine erfolgreiche Detektion liegt vor, wenn mindestens ein positives Klassifikatorergebnis in einen Zeitraum fällt, in dem das entsprechende Manöver vorlag. Wie in Kapitel 3.5.3 beschrieben kann damit gerechnet werden, dass der Manöverbeginn im Erfolgsfall mit einer Verzögerung von etwa Δt_e erkannt wird. Positive Klassifikatorausgaben, die nicht in den Zeitraum eines entsprechenden Manövers fallen, stellen falsch positive Ergebnisse dar.

Es wäre möglich, zu jedem Zeitpunkt zu prüfen, welches Ergebnis der Klassifikator

liefert und dies entsprechend in eine Konfusionsmatrix einzutragen. Allerdings können Start- und Endzeitpunkte von Manövern nur ungenau abgeschätzt werden. Zudem ist der Zeitraum, in dem die Erkennung eines Manöverbeginns zu erwarten wäre, nicht exakt definierbar. Da der Beginn eines Manövers nur einen kurzen Zeitraum umfasst, wären insbesondere die Ergebnisse für richtig positive und falsch negative Fälle sehr stark von der Definition in der Manöverdatenbank abhängig.

Aus diesem Grund werden Konfusionsmatrizen in dieser Arbeit nicht auf jeden einzelnen Zeitpunkt bezogen, sondern auf ganze Manöver und zusammenhängende Erkennungsintervalle. Da nicht als Manöver klassifizierte Zeitintervalle dabei nicht erfasst werden, können keine richtig negativen Fälle angegeben werden. Für das Beispiel aus Abb. 3.11 ergäbe sich somit folgende Konfusionsmatrix:

		Manöverdatenbank	
		Manöver _r	-
Klassifikator- ergebnis	Manöver _k	richtig positiv: 1	falsch positiv: 5
	-	falsch negativ: 1	richtig negativ: -

Wie üblich werden Klassifikatorergebnisse als Zeilen und die durch die Manöverdatenbank definierten richtigen Ergebnisse in den Spalten dargestellt. Der Index „r“ steht dabei für „real“, „k“ steht für „klassifiziert“.

Zwei wichtige Kenngrößen der Klassifikation sind die *Richtig-Positiv-Rate* RPR (auch *Sensitivität* genannt) und die *Falsch-Positiv-Rate* FPR

$$\text{RPR} = \frac{\text{richtig positiv}}{\text{richtig positiv} + \text{falsch negativ}} \quad (3.65)$$

$$\text{FPR} = \frac{\text{falsch positiv}}{\text{richtig negativ} + \text{falsch positiv}} \quad (3.66)$$

Die Richtig-Positiv-Rate trifft eine Aussage darüber, welcher Anteil der Manöver erkannt wurde.

Dem gegenüber besagt die Falsch-Positiv-Rate, wie hoch die Wahrscheinlichkeit für einen Falschalarm ist. Diese Größe ist allerdings für die intervallbasierte Auswertung mit Konfusionsmatrizen nicht berechenbar, da die benötigte Angabe von richtig negativen Fällen nicht gemacht werden kann.

Alternativ kann die *Falsch-Detektions-Rate* FDR angegeben werden, die besagt,

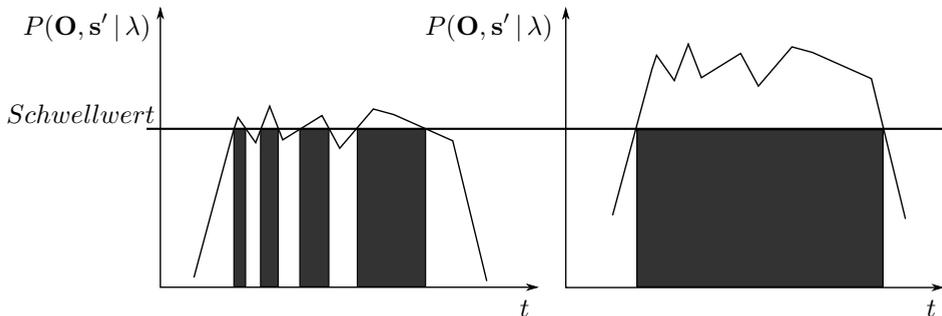


Abbildung 3.12: Wenn sich das Ähnlichkeitsmaß entlang des Schwellwertes bewegt, können mehrere kleine Intervalle entstehen, in denen die Schwelle durchbrochen wird (links). Liegt das Ähnlichkeitsmaß deutlich über dem Schwellwert, entsteht ein großes Intervall (rechts).

welcher Anteil an erkannten Manövern Fehlerkennungen waren.

$$\text{FDR} = \frac{\text{falsch positiv}}{\text{richtig positiv} + \text{falsch positiv}} \quad (3.67)$$

$$(3.68)$$

Ein Nachteil der intervallbasierten Darstellung ist in Abb. 3.12 ersichtlich. Wenn das Ähnlichkeitsmaß entlang des Schwellwertes verläuft, können mehrere kleine Zeitintervalle entstehen, die jedes für sich genommen als falsch positives Ereignis in die Konfusionsmatrix eingetragen werden. Falls das Ähnlichkeitsmaß weiter oberhalb des Schwellwertes liegt, entstehen meist einzelne größere, aber zusammenhängende Intervalle. Bei einer Sequenz wie in Abb. 3.12 gezeigt entstehen im linken Fall vier, im rechten Fall nur ein falsch positives Ereignis. Dies steht im Gegensatz zur tatsächlichen Klassifikatorleistung, denn im linken Fall werden kleinere Werte des Ähnlichkeitsmaßes erzeugt, der Klassifikator ist also „besser“ (näher an der Wirklichkeit) als derjenige auf der rechten Seite.

Trotz dieser Schwächen ist die Konfusionsmatrix ein brauchbares Hilfsmittel, um sich schnell einen Überblick über Klassifikatorleistungen machen zu können. Wie immer bei statistischen Auswertungen ist bei der Interpretation dieser Matrizen jedoch Vorsicht angebracht, um Fehlinterpretationen zu vermeiden. Es sollte zusätzlich die ROC-Kurve als komplementäres Kriterium hinzugenommen werden.

3.9.2.2 ROC-Kurven

In einer ROC-Kurve wird die *Richtig-Positiv-Rate* über der *Falsch-Positiv-Rate* aufgetragen.

Die Bestimmung der Richtig-Positiv-Rate erfolgt analog zur Aufstellung von Konfusionsmatrizen.

Bei der Auswertung der Falsch-Positiv-Rate tritt die oben beschriebene Schwierigkeit auf, zeitintervallbasierte Werte für richtig negative Fälle anzugeben. Aus diesem Grund wird die Falsch-Positiv-Rate nicht intervallbasiert ausgewertet, sondern auf jeden einzelnen Zeitschritt bezogen, in dem die Klassifikation durchgeführt wurde. Mit dieser Definition von falsch positiven und richtig negativen Ergebnissen pro Zeitschritt ergibt sich die zeitbasierte Darstellung

$$\text{FPR} = \frac{\text{Anzahl der Zeitschritte, in denen falsch klassifiziert wurde}}{\text{Gesamtzahl der Zeitschritte}} \quad (3.69)$$

$$= \frac{\text{Zeitraum, in dem falsch klassifiziert wurde}}{\text{Gesamtzeitraum}} \quad (3.70)$$

Eine Falsch-Positiv-Rate von $2 \cdot 10^{-5}$ bedeutet beispielsweise, dass bei 50 000 Klassifikatorauswertungen ein falsch positives Ergebnis vorlag. Bei der in dieser Arbeit verwendeten festen Updaterate von 12,5 Hz ist dies gleichbedeutend mit einem falsch positiv klassifizierten Zeitschritt von 80 ms Dauer pro 67 min Fahrzeit. Der Wert gibt jedoch keinen Aufschluss darüber, ob wirklich ein Falschalarm während eines einzelnen Zeitschrittes in 67 min Fahrzeit auftrat oder beispielsweise ein Falschalarm der Dauer von zwei Zeitschritten in 134 min Fahrzeit. Bezogen auf Abb. 3.12 würde also die Falsch-Positiv-Rate wie erwartet im linken Bild einen kleineren Wert erzeugen als im rechten Bild.

Der zur Beurteilung von Klassifikatoren relevante Bereich zeichnet sich durch sehr kleine Falsch-Positiv-Raten aus. Um die Darstellung mit sehr kleinen Abszissenwerten zu vermeiden und die Einschätzung der Ergebnisse zu erleichtern, wird in den folgenden ROC-Kurven die Darstellung der Falsch-Positiv-Rate in „Minuten pro einzeltem Falschalarm Zeitschritt“ (MPFZ) angegeben. Der zeitliche Bezug vermittelt ein besseres Gefühl für die Leistungsfähigkeit des Systems als eine direkte Angabe

der auf einem reinen Zählen der Zeitschritte beruhenden Falsch-Positiv-Rate.

$$\text{MPFZ} = \frac{80 \text{ ms}}{1000 \frac{\text{ms}}{\text{s}} \cdot 60 \frac{\text{s}}{\text{min}} \cdot \text{Falsch-Positiv-Rate}} \quad (3.71)$$

Die mit der vorliegenden Datenbank kleinstmögliche erfassbare Falsch-Positiv-Rate, also ein einzelner falsch klassifizierter Zeitschritt mit 80 ms Länge bezogen auf die gesamte Datenbank mit knapp 10 h Umfang ist gesondert markiert als *max* (maximale Anzahl an Minuten pro individuellem Falschalarm-Zeitschritt).

Die Ordinate der ROC-Kurven ist beschnitten auf Richtig-Positiv-Raten ab 50%, da kleine Erkennungsraten von untergeordnetem Interesse sind.

Für jede Wahl von Schwellwerten ergibt sich ein Punkt auf der ROC-Kurve. Die einzelnen Punkte werden in dieser Arbeit lediglich aus Darstellungsgründen miteinander verbunden.

Der ideale Klassifikator erzeugt einen Punkt bei einer Richtig-Positiv-Rate von eins und einer Falsch-Positiv-Rate von null bzw. ∞ bei einer Darstellung in „Minuten pro individuellem Falschalarm Zeitschritt“. Die Leistungsfähigkeit von realen Klassifikatoren kann basierend auf der Nähe der ROC-Kurve zu diesem idealen Punkt abgeschätzt werden.

Mit dieser Wahl der Darstellung komplementiert die ROC-Kurve die Konfusionsmatrix. Die Konfusionsmatrix zählt die Anzahl der Falschalarme, macht aber keine Aussage zur Dauer eines einzelnen Fehlers. Im Gegensatz dazu zeigt die gewählte Darstellung der ROC-Kurve den Anteil der Zeit, in dem der Klassifikator ein falsches Ergebnis liefert, macht aber keine Aussage darüber, ob diese Zeit aus vielen einzelnen oder aus weniger, aber dafür länger andauernden Fehlern besteht. Zusammen genommen geben die beiden Sichtweisen ein ausgewogenes Bild über die Klassifikatorleistung.

3.10 Erkennung von Fahrstreifenwechseln

3.10.1 Modelle

Es wurde jeweils ein Klassifikator zur frühzeitigen Erkennung von Fahrstreifenwechseln nach links und rechts trainiert. Als alleiniges Merkmal wurde die laterale Bewegung des Fahrzeugs im Fahrstreifen verwendet. Zusätzlich wurde eine Lokalisie-

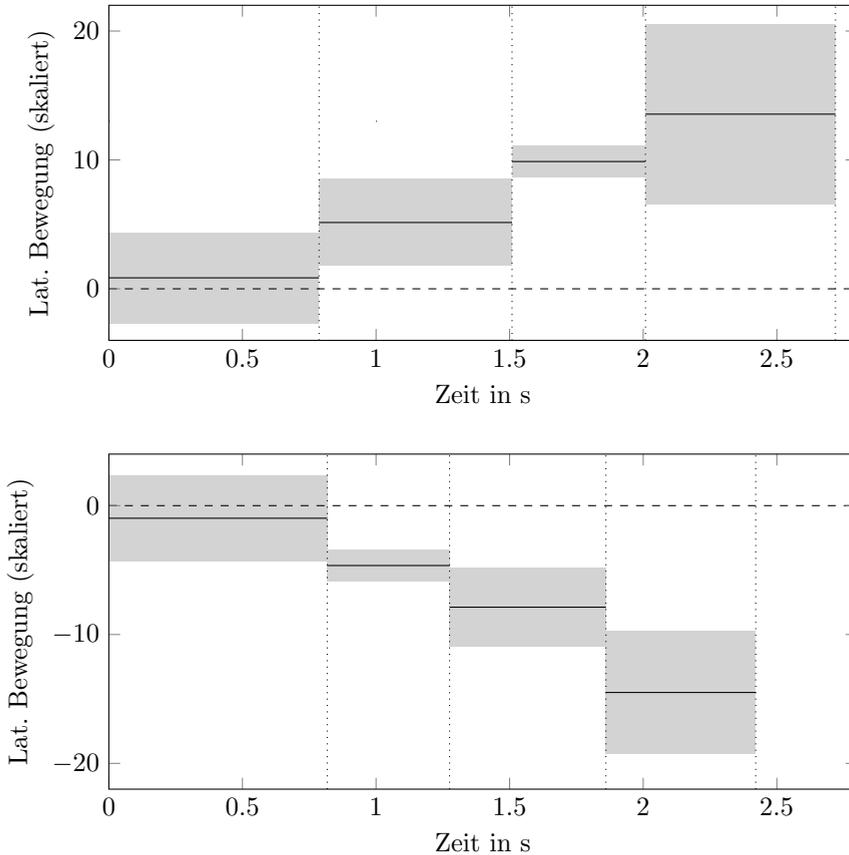


Abbildung 3.13: Darstellung der Emissionsverteilungen der Modelle für Abbiegevorgänge nach links (oben) und rechts (unten). Auf der Zeitachse ist die jeweilige erwartete Aufenthaltsdauer in den aufeinanderfolgenden Zuständen des Modells markiert. Auf der Ordinate ist der Mittelwert der Emissionsverteilung als Linie dargestellt, die Varianz ist als Box aufgetragen. Die Abszissenwerte sind aus numerischen Gründen skaliert und nicht absolut, sondern nur im Vergleich untereinander zu interpretieren.

rung in einer digitalen Straßenkarte verwendet, um in einem Vorverarbeitungsschritt die Manövererkennung für Fahrstreifenwechsel auf Straßen mit mindestens zwei Streifen pro Fahrtrichtung zu beschränken.

Aus dem initialen Modell von neun Zuständen wurden jeweils die ersten vier Zustände herausgeschnitten und zur Manöverstarterkennung genutzt. Die Zeitfenstergröße orientiert sich jeweils an den Aufenthaltsdauern entlang des typischen Pfades der ersten vier Zustände. Für Fahrstreifenwechsel nach links beläuft sich die Fenstergröße auf 2,71 s. Für Fahrstreifenwechsel nach rechts ist das Fenster mit 2,42 s leicht kleiner. Mit der in Abschnitt 3.8.2 beschriebenen Auflösung von 10 ms ergeben sich also 271 bzw. 242 Zeitschritte.

Abb. 3.13 zeigt eine Darstellung der Modelle. Sichtbar sind die vier Zustände mit ihren erwarteten Aufenthaltsdauern auf der Zeitachse sowie Mittelwert und Varianz der zustandsspezifischen Beobachtungen bezüglich des Merkmals der lateralen Bewegung auf der Ordinate. Die Modelle haben wie erwartet eine spiegelbildliche Ähnlichkeit um die Abszissenachse. Die Mittelwerte beim Modell für Fahrstreifenwechsellvorgänge nach links sind positiv (laterale Bewegung nach links), beim Modell nach rechts in entsprechender Größenordnung negativ (Bewegung nach rechts). Die absoluten Zahlenwerte sind aufgrund der in Abschnitt 3.4.3 beschriebenen Skalierungen nicht aussagekräftig.

Gut zu sehen ist auch die oben erwähnte kleinere Zeitdauer des Modells für Fahrstreifenwechsellvorgänge nach rechts. Insbesondere der unmittelbare Manöverbeginn scheint etwas rascher und vor allem gleichmäßiger ausgeführt zu werden. Bei den Testfahrten erschienen in der Tat Fahrstreifenwechsel nach rechts subjektiv gleichförmiger und weniger vorsichtig ausgeführt zu werden. Allerdings ist der Effekt klein und die Datenbasis ist zu gering, um statistisch fundierte Aussagen über unterschiedliches Fahrverhalten bei Fahrstreifenwechseln nach links bzw. rechts treffen zu können.

In Abb. 3.14 ist beispielhaft der Verlauf der Produktionswahrscheinlichkeit entlang des typischen Pfades dargestellt. Gut erkennbar ist, dass die grau markierten Manöver sich deutlich vom Rauschen abheben und über Schwellwertbildung gut identifizierbar sind.

3.10.2 Ergebnisse für Fahrstreifenwechsel nach links

Abb. 3.15 zeigt die ROC-Kurve der Erkennungsleistung für Fahrstreifenwechsel nach links. Man erkennt eine sehr gute Klassifikatorleistung bei einer niedrigen Anzahl von Falschalarmen.

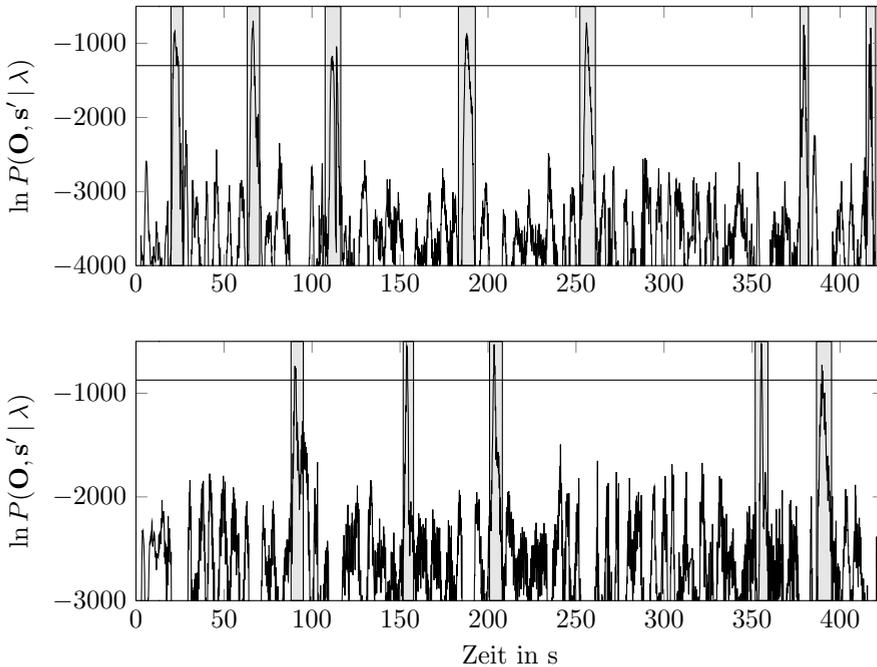


Abbildung 3.14: Produktionswahrscheinlichkeit entlang des typischen Pfades für Fahrstreifenwechsel nach links (oben) bzw. rechts (unten) während einer Autobahnsszene von ca. 6,5 min Dauer. Horizontal markiert ist jeweils ein Schwellwert. Die zugehörigen Manöver für Fahrstreifenwechsel nach links bzw. rechts sind grau eingerahmt.

Konfusionsmatrix Nr.1 aus der Abbildung zeigt, dass von den 136 zur Bewertung vorhandenen Manövern 128 erkannt werden konnten, ohne dass ein Falschalarm aufgetreten ist. 8 Manöver konnten nicht detektiert werden. Dies entspricht einer Richtig-Positiv-Rate von 94%.

Konfusionsmatrix Nr.2 markiert die Stelle auf der ROC-Kurve, bei der der erste Falschalarm auftritt. Der Punkt liegt auf der mit *max* markierten Abszisse, es handelt sich also um einen Falschalarm der Länge von 80 ms bezogen auf die ca. 10 h umfassende Datenbank. Die niedrigere Wahl des Schwellwertes zur Klassifikatorentscheidung bewirkt, dass ein weiteres Manöver korrekt erkannt werden konnte und die Richtig-Positiv-Rate leicht auf knapp 95% angestiegen ist.

Bei einer weiteren Senkung des Schwellwertes konnten zwei weitere Manöver korrekt

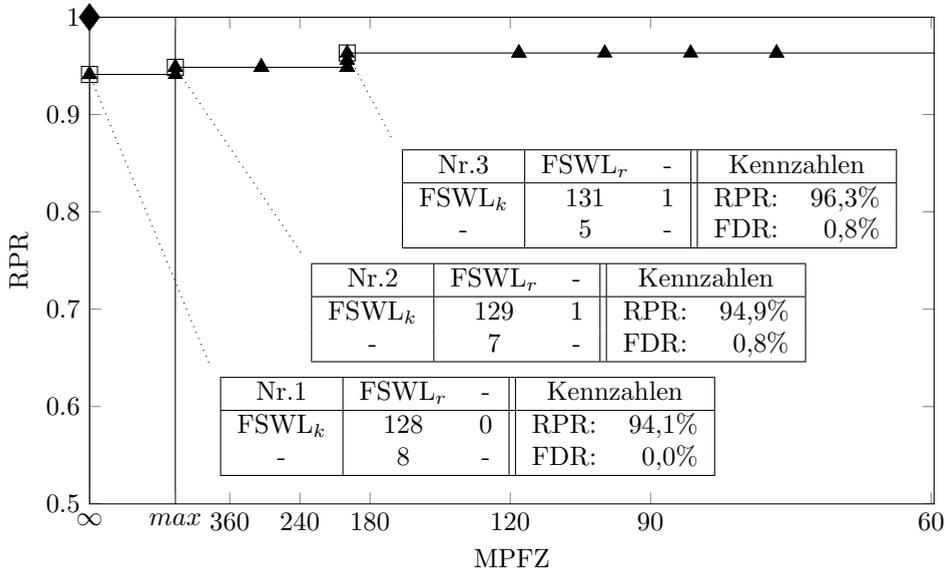


Abbildung 3.15: ROC-Kurve von Fahrstreifenwechseln nach links mit Konfusionsmatrizen und zugehörigen Kennzahlen an ausgewählten Stellen

erkannt werden, wie Konfusionsmatrix Nr.3 verdeutlicht. Die Richtig-Positiv-Rate liegt jetzt über 96%. Obgleich dieser Punkt bei einem höheren Abszissenwert liegt, bleibt es bei einem einzelnen falsch-positiven Ergebnis. Diese Fehlklassifikation dauert nun jedoch mehr als einen einzelnen Zeitschritt an. Dieser Umstand kann durch die zeitbasierte Darstellung in der ROC-Kurve sichtbar gemacht werden, in der intervallbasierten Konfusionsmatrix jedoch nicht.

Im weiteren Verlauf der ROC-Kurve ist eine Seitwärtsbewegung zu erkennen, d.h. selbst bei weitergehender Senkung des Schwellwertes konnten keine höheren Erkennungsraten erreicht werden.

3.10.3 Ergebnisse für Fahrstreifenwechsel nach rechts

Für Fahrstreifenwechsel kann eine vergleichbar gute Leistung erreicht werden wie für Fahrstreifenwechsel nach links. Wie in Abb. 3.16 gezeigt kann eine Richtig-Positiv-Rate von 95% ohne Falschalarm erreicht werden, bevor ein erster Falschalarm in Form eines einzelnen Zeitschrittes auftritt. Auch hier ist wieder eine Seitwärtsbewegung

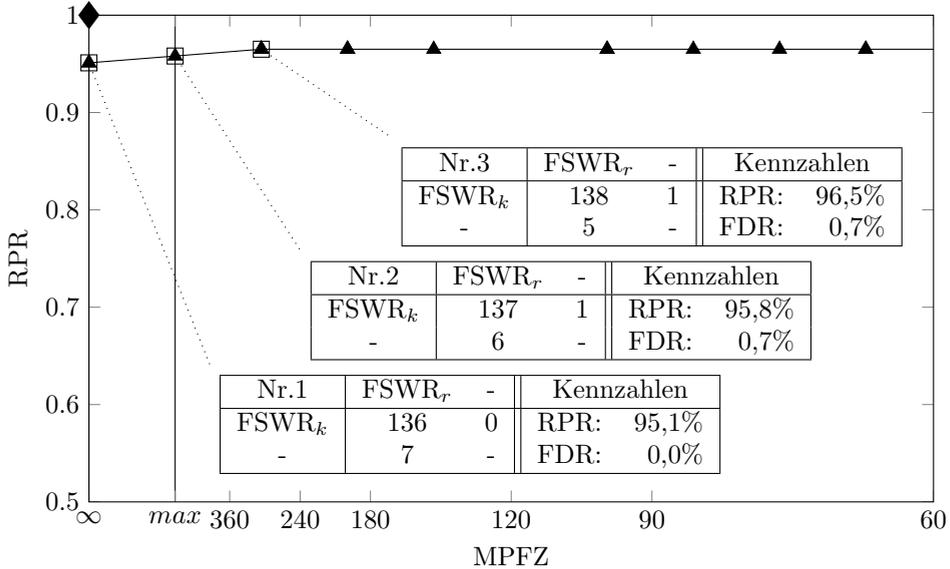


Abbildung 3.16: ROC-Kurve von Fahrstreifenwechsell nach rechts mit Konfusionsmatrizen und zugehörigen Kennzahlen an ausgewählten Stellen

bei einer Erkennungsrate von gut 95% zu betrachten, wobei die steigende Falsch-Positiv-Rate auch hier wieder zunächst durch eine Verlängerung der Fehldetektion auf mehrere Zeitschritte zurückzuführen ist, so dass die Falsch-Detektions-Rate zunächst gleich bleibt.

3.10.4 Diskussion

3.10.4.1 Fehler des Klassifikators

Die Klassifikatoren für Fahrstreifenwechsel schaffen es nicht, alle Manöver zu detektieren. Selbst bei der Wahl eines vergleichsweise niedrigen Schwellwertes verbleiben verpasste Manöver. Zusätzlich erzeugen die Klassifikatoren bei entsprechender Schwellwertwahl Falschalarne. Um herauszufinden, wodurch diese Fehler verursacht werden, wurden die entsprechenden Szenen analysiert.

Bei Fahrstreifenwechsell nach links wurden wie in Abb. 3.15 gezeigt insgesamt fünf Manöver nicht erkannt. Bei näherer Betrachtung der Manöver konnte festge-

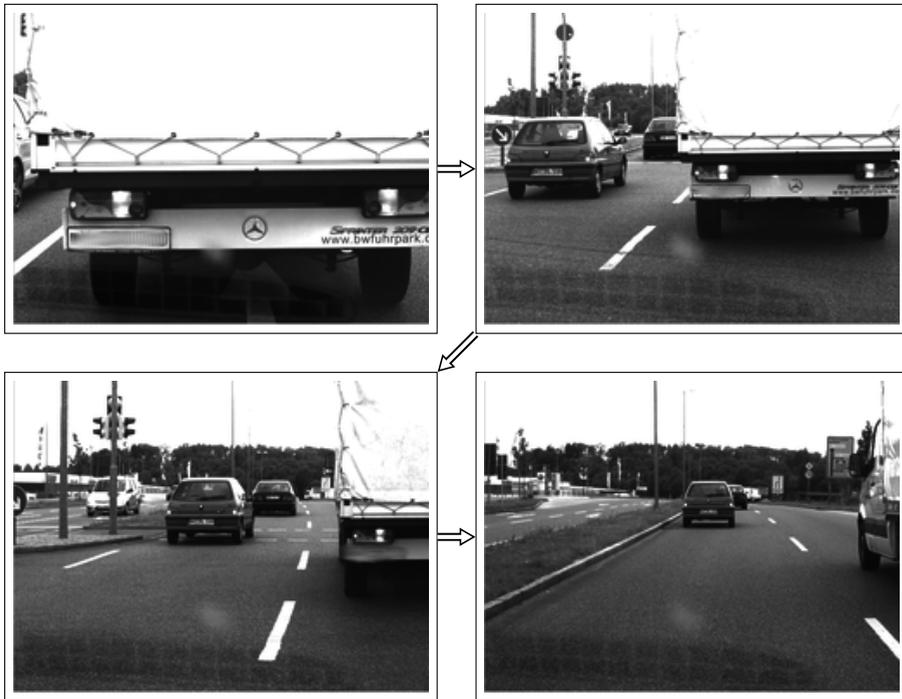


Abbildung 3.17: Beispielszene eines falsch-negativen Resultats: Das Manöver eines Fahrstreifenwechsels inmitten einer Kreuzung konnte nicht erkannt werden, da die Fahrstreifenenerkennung das Eingangssignal der lateralen Position des Fahrzeugs im Streifen nicht liefern konnte.

stellt werden, dass diese Fehler ausnahmslos durch Probleme in der vorgelagerten videobasierten Fahrstreifenenerkennung verursacht wurden.

Die Gründe für Fehler in der Fahrstreifendetektion lagen in zwei Fällen bei verwiterten und damit schlecht sichtbaren Fahrstreifenmarkierungen. In einem Fall war die Straße selbst zerklüftet und hat viele störende Kanten im Videobild verursacht.

Eine andere Klasse von Fehlern der Fahrstreifenenerkennung kam durch vorausfahrende Lkw zustande. Diese Fahrzeuge erzeugen einerseits selbst viele Störkanten im Videobild, gegen die die in einer Studienarbeit entwickelte Fahrstreifenenerkennung nicht immer robust arbeitete. Andererseits sind aufgrund der größeren Breite dieser Objekte bei dichter Fahrgeschwindigkeit die Markierungen auf der Straße schon in kurzen

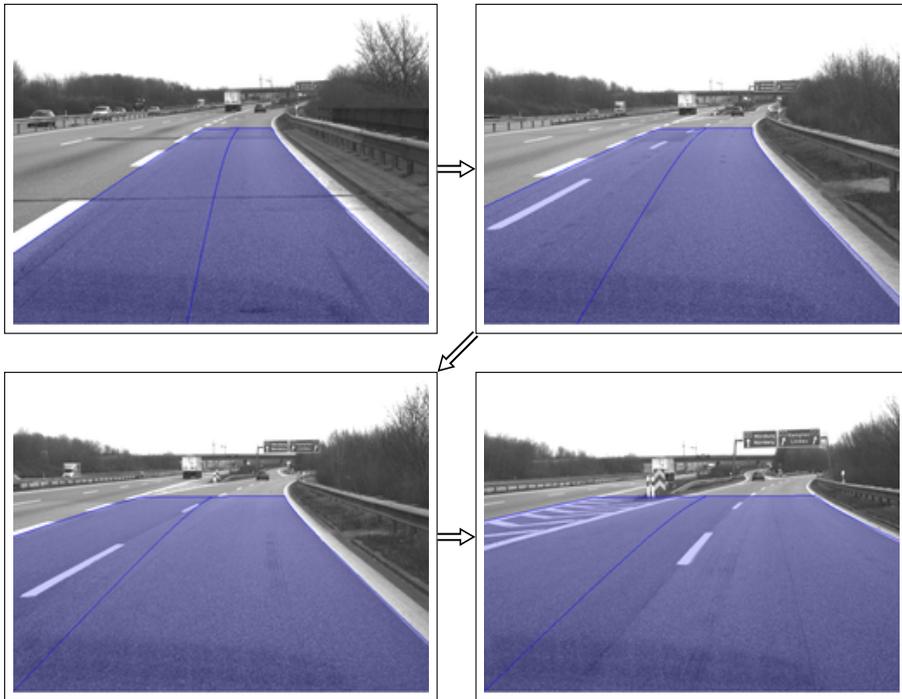


Abbildung 3.18: Szene, bei der aufgrund einer fehlerhaften Fahrstreifenerkennung unter Umständen ein Manöver in die falsche Richtung erkannt wird.

Distanzen nicht mehr sichtbar.

Ein Beispiel für einen solchen Fehler ist in Abb. 3.17 zu sehen, dargestellt in vier Einzelbildern. Zu Beginn steht das Versuchsfahrzeug an einer Ampel hinter einem Transporter, Bild links oben. Die Markierungen auf der Straße sind im Kamerabild kaum sichtbar. Nach dem Anfahren wechselt der Testfahrer noch im Kreuzungsbereich auf den linken Fahrstreifen. Die Fahrstreifenerkennung konnte bis zum Abschluss des Manövers keine Schätzung der Markierungen liefern.

Ein besonders interessantes Szenario ist in Abb. 3.18 dargestellt. Das Versuchsfahrzeug befindet sich auf dem Ausfahrtfahrstreifen eines Autobahnkreuzes, Bild links oben. Die zunächst nur aus einem Streifen bestehende Abzweigung teilt sich in zwei Fahrstreifen auf, Bilder rechts oben und links unten. In diesem Szenario verpasst die Fahrstreifenerkennung die Aufteilung, so dass beide Streifen zusammen erkannt wer-

den, wie aus der Schattierung ersichtlich ist. Die geschätzte Mittellinie des Streifens wird in der Abbildung als durchgezogene Linie im schattierten Bereich dargestellt. In Folge der einseitigen deutlichen Überschätzung der Fahrstreifenbreite wandert die geschätzte Mittellinie nach links. Aus Sicht der Manövererkennung bewegt sich das Fahrzeug kontinuierlich nach rechts im Fahrstreifen. In diesem Szenario vollzieht der Testfahrer einen Fahrstreifenwechsel nach links, wie aus dem Bild rechts unten erahnt werden kann. Dieses kann aufgrund der fehlerhaften Fahrstreifenenerkennung nicht detektiert werden. Andererseits bewirkt die falsch geschätzte Bewegung des Fahrzeugs nach rechts unter Umständen einen Falschalarm für das Manöver eines Fahrstreifenwechsels nach rechts.¹⁹ Das Szenario hat damit das Potential, einen Fahrstreifenwechsel in die falsche Richtung zu erkennen und damit gleichzeitig ein falsch-negatives und ein falsch-positives Klassifikatorergebnis hervorzubringen.

Für Fahrstreifenwechsel nach rechts sieht das Ergebnis leicht verändert aus. Auch wenn ebenfalls alle fünf nicht erkannten Fahrstreifenwechselmanöver nach rechts auf eine fehlerhafte Fahrstreifenenerkennung zurückzuführen sind, traten diese ausnahmslos bei Abfahrten von Autobahnen oder Bundesstraßen auf. Diese Szenarien sind komplexer und fehlerträchtiger für die Fahrstreifenenerkennung. Die Detektion von Wechseln nach rechts bei normalen Autobahnszenarien ist noch robuster als bei Wechseln nach links. Dies kann eine weitere Folge der zu Beginn des Kapitels erwähnten Beobachtung sein, dass Fahrstreifenwechsel nach rechts tendentiell „gutmütiger“ ausgeführt werden.

Falsch-positive Ereignisse konnten bei beiden Klassifikatoren bei entsprechender Wahl des Schwellwerts vollständig vermieden werden. Bei Senkung der Schwellwerte kam es jeweils zuerst beim Schneiden von Kurven zu Falschalarmen.

Insgesamt ist festzustellen, dass die Klassifikatoren eine sehr gute Erkennungsleistung liefern und Verbesserungspotential weniger in den Klassifikatoren selbst, sondern vor allem in der Güte der Merkmale besteht. Es ist zu erwarten, dass das Ergebnis mit weiter ausgereiften Fahrstreifenenerkennungsmethoden noch einmal deutlich verbessert werden könnte.

3.10.4.2 Erkennungszeitpunkt der Manöver

Neben der richtigen Klassifikation der Manöver wurde eine möglichst frühzeitige Erkennung angestrebt. Da der Zeitpunkt des Manöverbeginns nicht exakt definierbar ist,

¹⁹Das vermeintliche Manöver entspricht keinem typischen Fahrstreifenwechsel. Es hat ein niedriges Ähnlichkeitsmaß und tritt erst bei entsprechend niedriger Wahl des Schwellwertes als Falschalarm in Erscheinung.

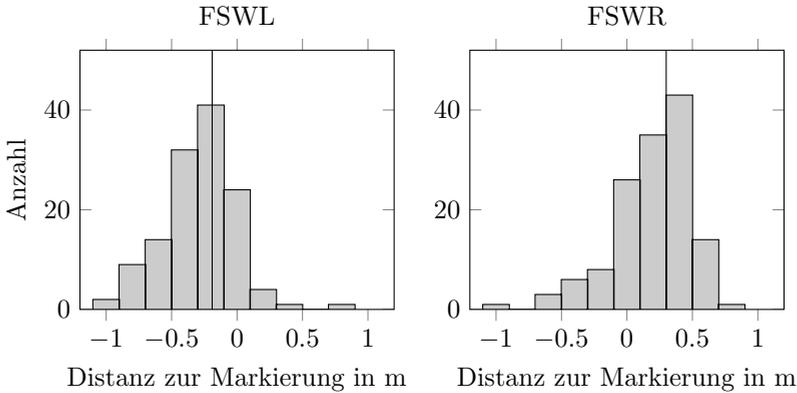


Abbildung 3.19: Histogramm der Erkennungszeitpunkte der Manöver für Fahrstreifenwechsel nach links (linkes Bild) und nach rechts (rechtes Bild), gemessen als Distanz zur zu überquerenden Fahrstreifenmarkierung. Positive Distanzen bedeuten Erkennung vor Berühren der Fahrstreifenmarkierung mit dem äußeren Fahrzeugrand. Der Mittelwert ist jeweils als vertikale Linie eingezeichnet.

wird als Maß keine zeitliche Größe, sondern der Abstand des äußeren Fahrzeugrands von der zu überquerenden Fahrstreifenmarkierung genommen.

Abb. 3.19 zeigt die Verteilung der Abstände zur Fahrstreifenmarkierung zum Klassifikationszeitpunkt für Fahrstreifenwechsel nach links bzw. rechts. Auch hier ist wieder zu beobachten, dass Fahrstreifenwechsel nach rechts früher erkannt werden können als entsprechende Manöver nach links. Während bei Wechseln nach rechts das Manöver im Mittel mit 30 cm deutlich vor Überqueren des Fahrstreifens erkannt werden kann, war dies bei Manövern nach links bei vielen Fällen erst kurz nach Kreuzen der Markierung möglich, im Mittel mit knapp 20 cm etwa eine Reifenbreite.

Dieses Ergebnis ist sowohl konsistent mit dem bei Fahrstreifenwechseln nach rechts kleiner ausfallenden Zeitfenster (vergleiche Abschnitt 3.10.1) als auch mit der Beobachtung, dass Fahrstreifenwechsel nach rechts tendentiell gutmütiger ausgeführt werden.

Extrema von einer Erkennung nach einem halben Meter nach Überfahren der Markierung oder später sind wiederum auf Probleme in der Fahrstreifenerkennung zurückzuführen. Generell ist bei Betrachten dieser Auswertung zu beachten, dass hinsichtlich des Erkennungszeitpunktes keine absolute Referenz aufgenommen werden

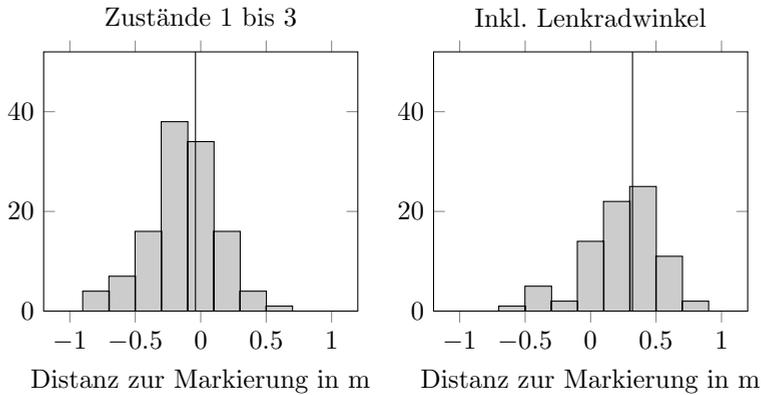


Abbildung 3.20: Histogramm der Erkennungszeitpunkte für Modifikationen des Modells zur Erkennung von Fahrstreifenwechseln nach links: Links Beschränkung auf die ersten drei anstatt vier Zustände, rechts unter Einbeziehung des Radlenkwinkels. Der Mittelwert ist jeweils als vertikale Linie gezeichnet.

konnte, sondern nur die Ergebnisse der Fahrstreifenenerkennung vorliegen. Da diese fehlerbehaftet arbeitet, sind im Folgenden Tendenzen aussagekräftiger als absolute Werte.

Um zu untersuchen, in wie weit eine frühere Erkennung auch von Fahrstreifenwechseln nach links erreicht werden kann, wurde das Modell modifiziert. Anstatt der ersten vier Zustände wurden nur die ersten drei Zustände herausgeschnitten und das Zeitfenster entsprechend auf die für diese Zustände typische Größe adaptiert. Im Resultat beschränkt sich das Modell auf eine noch frühere Phase beim Fahrstreifenwechselvorgang. Es ist insgesamt kürzer. Damit ist zu erwarten, dass es früher während eines Manövers passt, auf Kosten einer weniger ausgeprägten Abgrenzung gegenüber normalem Fahrstreifenverfolgen und damit höherer Anfälligkeit für Fehlerkennungen.

Der erwartete Effekt einer früheren Erkennung konnte nachgewiesen werden. Im Mittel konnten die Manöver nun bereits beim Berühren der Fahrstreifenmarkierung erkannt werden und damit fast 20 cm früher.

Eine weitere Möglichkeit, den Erkennungszeitpunkt nach vorne zu verlagern, ist die Einbeziehung des Radlenkwinkels abweichend zur Fahrstreifenhaltung als zusätzliches Signal. Da die Lenkbewegung i.Allg. die Ursache der lateralen Bewegung ist, hat der Klassifikator mit dieser Zusatzinformation die Möglichkeit, früher zu reagieren. Es ergab sich eine weitere deutliche Verlagerung des Erkennungszeitpunktes auf im Mittel

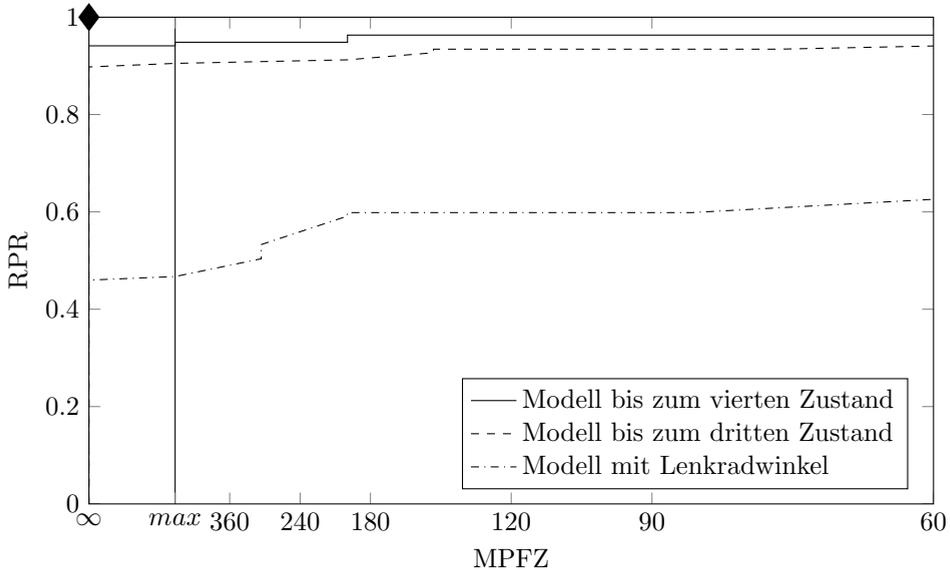


Abbildung 3.21: Modelle zur früheren Erkennung des Manövers neigen eher zur Störanfälligkeit

über 30 cm Abstand zur Markierung, insgesamt also eine Verbesserung um knapp einen halben Meter. Abb. 3.20 stellt die Histogramme des Erkennungszeitpunktes der beiden Modellmodifikationen gegenüber.

Beide Modellmodifikationen lassen jedoch eine Verringerung der Robustheit des Klassifikators erwarten, und auch diese Erwartung konnte nachgewiesen werden. Das verkürzte Modell passt schneller auf geschnittene Kurven. Das Radlenkwinkelsignal reagiert zwar schnell, ist aber sensibel gegenüber unruhigem Fahren und Pendelbewegungen im eigenen Fahrstreifen. Abb. 3.21 zeigt die ROC-Kurven im direkten Vergleich.

3.11 Erkennung von Abbiegemanövern

3.11.1 Modelle

Abbiegemanöver werden über jeweils ein Modell für Abbiegevorgänge nach links und rechts erkannt. Alleiniges Merkmal für die Hidden-Markov-Modelle ist der Lenk-

winkel²⁰. Wiederum wurde die Lokalisierung auf einer digitalen Karte verwendet, um die Manövererkennung auf die räumliche Nähe zu Kreuzungen zu beschränken. Abbiegevorgänge werden nur im Umkreis von 40 m um den Kreuzungsbereich zugelassen. Zusätzlich muss ein Abbiegevorgang in die jeweilige Richtung möglich (aber nicht unbedingt erlaubt) sein.

Auch für die Erkennung von Abbiegevorgängen wurde von einem initial parametrisierten Modell mit neun Zuständen ausgegangen. Allerdings wurde bei der Extraktion des Teilmodells im Gegensatz zur Erkennung von Fahrstreifenwechseln nicht auf die ersten Zustände zurückgegriffen, sondern es wurden die Zustände drei bis sechs herangezogen. Es wurden auch Untersuchungen mit einer anderen Wahl von Zuständen (z. B. ab dem ersten Zustand) durchgeführt. Jedoch hat sich herausgestellt, dass Abbiegemanöver einerseits sehr variabel sind und sich andererseits zu Beginn nur wenig von normaler Folgefahrt unterscheiden, so dass die ersten Zustände im Modell nicht zur Separation beitragen, sondern das Erkennungsergebnis nur unvorteilhaft glätten.

Als Zeitfenstergröße wurde für Abbiegevorgänge nach links 2,90 s und für Abbiegevorgänge nach rechts 3,30 s gewählt. Die nicht genutzten ersten beiden Zustände eingeschlossen repräsentiert das Modell knapp über die Hälfte der Dauer eines durchschnittlichen Abbiegevorgangs in der Labeldatenbank, was auch den erwarteten Erkennungszeitpunkt darstellt.

Bei Abbiegevorgängen sind Start- und Endzeitpunkte der Manöver noch weniger eindeutig als bei Fahrstreifenwechseln. Zudem fehlt hier ein konsistent definierbarer, automatisiert auswertbarer Referenzzeitpunkt, wie er bei Fahrstreifenwechseln mit dem Berühren der Markierung angebar war. Aus diesem Grund sind die zeitlichen Aspekte der Erkennung bei Abbiegevorgängen wenig aussagekräftig und werden im Folgenden nur am Rande erwähnt. Die oben angegebene Zeitfenstergröße, die den zu erwartenden Erkennungszeitpunkt impliziert, umfasst weniger als die Hälfte der gesamten Manöverdauer.

3.11.2 Ergebnisse für Abbiegemanöver nach links

Abb. 3.22 zeigt die ROC-Kurve des Klassifikators für Abbiegemanöver nach links. Auch für dieses Manöver konnte eine gute Erkennungsleistung erzielt werden.

Wie man an der markierten Konfusionsmatrix Nr.1 erkennt, konnten von den 42 zur

²⁰Im Gegensatz zum Radlenkwinkel ist der Lenkwinkel direkt messbar. Der Vorteil des Radlenkwinkels, dass die Fahrstreifenkrümmung kompensiert werden konnte, ist im Kreuzungsbereich aufgrund fehlender Krümmungsinformation nicht gegeben.

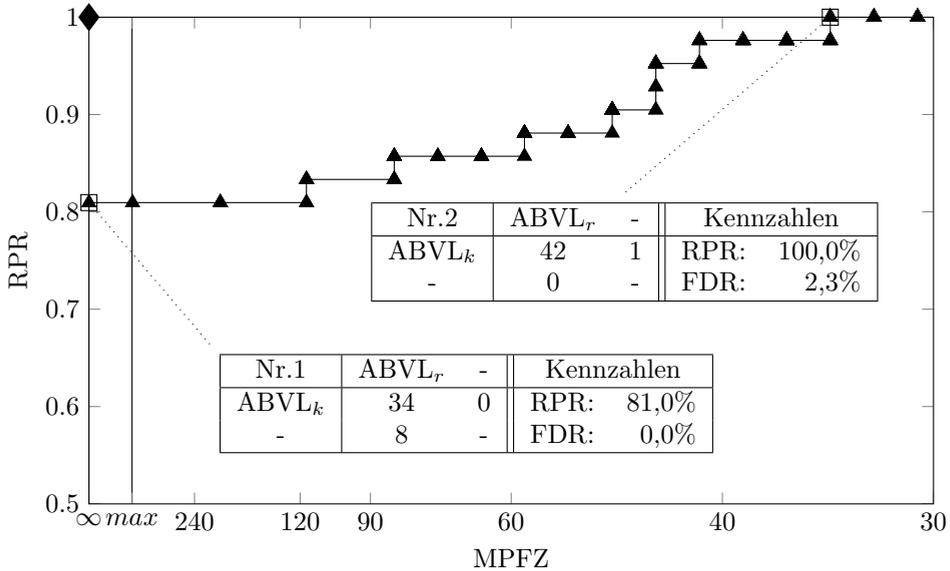


Abbildung 3.22: ROC-Kurve von Abbiegemanövern nach links mit Konfusionsmatrizen und zugehörigen Kennzahlen an ausgewählten Stellen

Auswertung herangezogenen Manöver 34 erkannt werden, ohne dass ein Falschalarm auftrat. Dies entspricht einer Richtig-Positiv-Rate von 81%.

Konfusionsmatrix Nr.2 markiert die Stelle an der ROC-Kurve, bei der alle Abbiegemanöver nach links erkannt werden konnten. Allerdings wurde in diesem Fall auch ein Falschalarm erzeugt.

Bemerkenswert ist, dass über den gesamten Verlauf der abgebildeten ROC-Kurve nur ein einzelner Falschalarm auftrat. Wie in Abschnitt 3.9.2 erläutert, basiert die Falschalarm-Achse der ROC-Kurven auf dem Anteil der Zeitschritte, in denen falsch klassifiziert wurde. Im vorliegenden Fall handelt es sich um eine einzelne Situation, von der mit sinkendem Schwellwert ein immer längerer Anteil fehlerhaft ausgewertet wird.

Bei dem betreffenden Szenario ist der Fahrer einem im Kreuzungsbereich laufenden Fußgänger ausgewichen. Diese Ausweichbewegung wurde bei entsprechender Schwellwertwahl als Einleiten eines Abbiegemanövers nach links klassifiziert. Dieses Ergebnis ist zwar eine Fehlklassifikation, zeigt aber eine Bewegung des Fahrzeugs weg vom Fußgänger an. Wird der Klassifikator beispielsweise als Teil eines Assistenzsystems

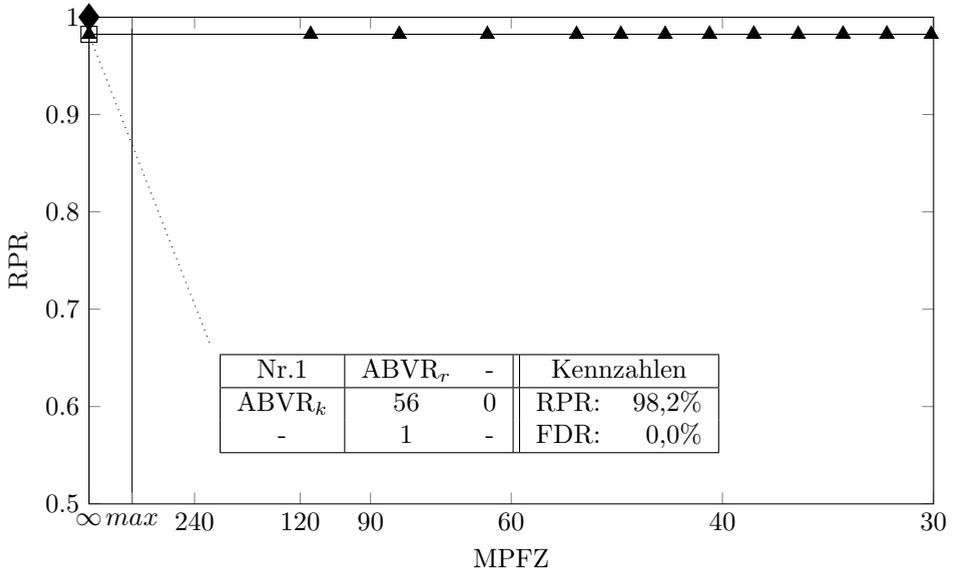


Abbildung 3.23: ROC-Kurve von Abbiegemanövern nach rechts mit Konfusionsmatrizen und zugehörigen Kennzahlen an ausgewählten Stellen

für Fußgängerschutz genutzt, wären Fehlklassifikationen dieser Art unkritisch.

3.11.3 Ergebnisse für Abbiegemanöver nach rechts

In Abb. 3.23 ist die ROC-Kurve des Klassifikators für Abbiegemanöver nach rechts dargestellt. Es konnte eine sehr gute Erkennungsleistung erreicht werden.

Wie in Konfusionsmatrix Nr.1 ersichtlich beträgt die eine Richtig-Positiv-Rate der Erkennung 98%, ohne dass ein Falschalarm aufgetreten ist. Lediglich ein Manöver konnte nicht erkannt werden.

Eine Senkung der Schwellwerte führte zu einer steigenden Anzahl und Dauer von Falschalarmen, ohne dass das verbleibende Manöver erkannt werden konnte.

Die Analyse des Fehlers hat gezeigt, dass in diesem Fall das GPS-Signal für einen längeren Zeitraum ausgefallen ist. Die Position des Fahrzeugs auf der digitalen Navigationskarte wurde auf einer Stelle fernab von Kreuzungen gehalten. Da die

Abbiegerkennung auf Kreuzungsbereiche beschränkt ist, kann dieses Manöver nicht mehr durch die Klassifikatoren erkannt werden, unabhängig von der Schwellwertwahl.

Aus Sicht des Klassifikators konnte auf dem vorliegenden Datensatz demnach ein perfektes Ergebnis erreicht werden. Der Fehler kann nur durch Verbesserung der Eingangssignale vermieden werden, z. B. durch Positionierung mithilfe Koppelnavigation bei Ausfall des GPS-Empfangs.

Wie bei der Erkennung von Fahrstreifenwechseln wurde auch für Abbiegemanöver der Effekt sichtbar, dass Manöver nach rechts tendentiell leichter zu erkennen sind als Manöver nach links. In der Datenbasis wurden Ausweichvorgänge, kleine Schlenker in der Fahrweise und das Schneiden von Kurven vor allem nach links ausgeführt.

3.12 Abhängigkeit der Klassifikation vom Fahrer

Von den 9 verschiedenen Fahrern, die zur Datenbasis beigetragen haben, wurden die Manöver von jeweils 5 Fahrern nicht für das Training verwendet. Leider wird die Datenbasis bei der Beschränkung auf einzelne Fahrer so klein, dass keine statistische Auswertung mehr möglich ist. Es sei lediglich angemerkt, dass die Erkennungs- und Fehlerraten für die Fahrer, die nicht im Trainingsset vertreten waren, sich ähnlich wie die Werte im vorangegangenen präsentierten Gesamtergebnis verhielten. Die Variabilität aufgrund der unterschiedlichen Szenarien erscheint deutlich größer als die Fahrstile der Testfahrer, was die Untersuchungen von Klanner [Kla08] bestätigt.

3.13 Vergleichbarkeit der Ergebnisse

Es wäre interessant, die unterschiedlichen publizierten Systeme zur Manövererkennung hinsichtlich ihrer Leistungsfähigkeit gegenüberzustellen. Leider gibt es vielfältige Faktoren, die einen großen Einfluss auf die Leistungsdaten eines Systems haben. Wie schon im Abschnitt 3.1 bezüglich des Standes der Technik dargelegt, gibt es diverse Design-Entscheidungen, die sowohl Erkennungsleistung als auch den Zeitpunkt der Erkennung signifikant beeinflussen. Zu den Faktoren zählen z. B., ob die Versuche in einem Simulator oder im Straßenverkehr vorgenommen würden, ob Fahrerbeobachtungssensorik eingesetzt wurde, ob zu fahrende Manöver angesagt wurden, wie Erkennungszeitpunkte bestimmt werden und vieles mehr. Zusätzlich stehen Erkennungsraten und Erkennungszeitpunkt in Konkurrenz zueinander, wie in Abschnitt 3.10.4.2 aufgezeigt wurde – Angaben zu Erkennungsraten ohne Erken-

nungszeitpunkte sind deshalb nicht vergleichbar. Selbst die Auswertemethodik an sich, in dieser Arbeit als Kombination von ROC-Kurven und Konfusionsmatrizen aufgesetzt und ausführlich in Abschnitt 3.9.2 beschrieben, ist nicht einheitlich, und in Publikationen meist nicht angegeben.

In der Literatur gibt es Gegenüberstellungen von Erkennungsergebnissen (z. B. [DT11]), die diese Faktoren i.Allg. ignorieren. Um wirkliche Vergleichbarkeit zu schaffen, müsste ein Benchmark-System definiert werden, das einheitliche Vergleichsbedingungen schafft. Dies könnte Inhalt zukünftiger Arbeiten sein.

Kapitel 4

Gefahrenbewertung

Im Zentrum von Sicherheitsanalysen technischer Systeme steht der Begriff des *Risikos*. Risiko ist dabei definiert als mögliches Ausgesetztsein eines zu Schaden führenden Ereignisses in Kombination mit dem zu erwartenden Schadensausmaß [Hil12].

Bei der Beurteilung der Gefährdung durch ein technisches System im Automobilbereich hinsichtlich funktionaler Sicherheit kommt nach ISO 26262 als dritte Einflussgröße noch die Beherrschbarkeit durch den Fahrer hinzu [ISO11].

Die Definition des Risikos findet sich auch in Ansätzen zu Bewertung der Gefährlichkeit von Fahrsituationen wieder. Die Modellierung muss dabei aus Komplexitätsgründen stark vereinfacht werden. Rodemerk und Habenicht beispielsweise erlauben in [HWB⁺11; RHW⁺12] eine maximale Beschleunigung des eigenen Fahrzeugs, die durch Längsbeschleunigung oder Bremsen in Fahrzeuginnenrichtung und durch Lenken in Fahrzeugquerrichtung aufgeteilt werden kann. Das Vorgehen ist analog zur Betrachtung des Kammschen Kreises [Mit04; Zom91], der in diesem Fall jedoch nicht mit dem Reibschluss, sondern mit einer als Design-Parameter aufgefassten kleineren maximalen Beschleunigung gebildet wird. Bei einer Prädiktion entsprechend der maximal angenommenen Beschleunigung ergibt sich für den zukünftigen Aufenthaltsort eine Kreisfläche. Unter der Annahme von deterministischer Prädiktion der Kollisionsgegner wird der belegte Teil der Kreisfläche als Kollisionswahrscheinlichkeitsmaß eingeführt. Das Kollisionswahrscheinlichkeitsmaß ist also direkt abhängig von dem Modellparameter der erlaubten Beschleunigung. Die Kollisionswahrscheinlichkeit wird vereinfachend als Aufprallfaktor angenähert, der linear in die Risikoabschätzung eingeht.

Daniel et. al. ordnen das Risiko in diskrete Klassen „niedrig“, „mittel“ und „hoch“ ein [DLBB13]. Einfluss auf die Klassifizierung haben Fahrzeug, Fahrer und Umgebung. Zunächst werden für Fahrzeug, Fahrer und Umgebung einzeln Risiken ermittelt und mit der Evidenztheorie nach Dempster und Shafer kombiniert. Fahrzeugrisiken

ergeben sich dabei u.a. aus Fahrzeugalter und Kilometerstand, Fahrerrisiken aus Alter, Geschlecht und Erfahrung. In die Risiken der Umgebung gehen Datum, Uhrzeit und Straßentopologie ein. Ausgewertet wurde das Verfahren simulativ.

Die Arbeit von Siordia et. al. führt ähnliche Abschätzungen speziell für Lastkraftwagen durch [SDC⁺10]. Auch in diesem Fall werden die bestimmenden Eingänge in die Bewertung aus dem Bereich des Fahrers (z. B. durch Auswertung, ob der Fahrer die Hände am Lenkrad hat), des Fahrzeugs (u.a. bestimmt durch die Geschwindigkeit) und der Straße (z. B. beeinflusst durch die Steigung) bezogen. Die trainierten Datamining-Algorithmen wurden im Fahrsimulator getestet und einer Expertenklassifikation gegenübergestellt. Dabei ergab sich eine gute Übereinstimmung der gelernten Szenarien. Die Generalisierungseigenschaften waren allerdings weniger gut.

Basis der Gefahrenbewertung im Rahmen der vorliegenden Arbeit ist die Notation der *Kollisionswahrscheinlichkeit*, für deren effektive und effiziente Bestimmung, insbesondere in probabilistischem Umfeld, Forschungsbedarf besteht. Im folgenden Kapitel wird zunächst die Notation der Kollisionswahrscheinlichkeit angegeben. Ansätze in der Literatur zur Betrachtung der Kollisionswahrscheinlichkeit und ihrer zeitlichen Gewichtung werden ebenfalls in diesem Abschnitt rekapituliert. Im Anschluss werden verschiedene neuartige Methoden vorgestellt, die Kollisionswahrscheinlichkeit zu berechnen oder zumindest anzunähern. Danach werden diese Methoden in einer Auswertung hinsichtlich Rechenaufwand und Approximationsfehler verglichen.

4.1 Übersicht zur Gefahrenbewertung mit Kollisionswahrscheinlichkeiten

4.1.1 Kollisionswahrscheinlichkeit

Die Kollisionswahrscheinlichkeit hängt von zukünftigen operativen Aktionen¹ der beteiligten Fahrer ab. Es sei mit \mathcal{U}_t der multidimensionale Raum aller zukünftigen Aktionen aller Fahrer bis zum Zeitpunkt t gekennzeichnet. Für gegebene Eingänge aus \mathcal{U}_t kann untersucht werden, ob diese Konfiguration zu einem Kollisionsereignis \mathcal{C} führt. Unter Vernachlässigung von Fahrzeugmodellfehlern führt dies auf eine binäre Wahrscheinlichkeitsverteilung [BBK05].

$$P_t(\mathcal{C}|\mathcal{U}) = \begin{cases} 1 & \text{falls bis Zeitpunkt } t \text{ eine Kollision eintritt} \\ 0 & \text{sonst} \end{cases} \quad (4.1)$$

¹wie z. B. Brems- und Lenkbewegungen

Die Kollisionswahrscheinlichkeit ergibt sich im allgemeinen Fall aus der Randverteilung über alle möglichen Systemeingänge bis zum Zeitpunkt t

$$P_t(\mathcal{C}) = \int_{u \in \mathcal{U}_t} P(\mathcal{C} | u) P(u) du \quad (4.2)$$

Hier wirkt der schaltende Term $P(\mathcal{C} | u)$ wie eine Abgrenzung im Raum der möglichen Eingänge \mathcal{U}_t .

Je nach Anwendungsfall kann die Auswertung von (4.2) verschiedene Formen annehmen. Wenn sichergestellt werden soll, dass eine Bewertung bei beliebigen physikalisch möglichen Fahrerreaktionen abgegeben werden kann [AWK⁺12], muss der gesamte mit dem Reibschluss gebildete Kammsche Kreis berücksichtigt werden. Dies ist rechenaufwändig und vor allem zur Kurzzeitprädiktion geeignet. In [KSD09] beispielsweise wird dieses Verfahren eingesetzt, um ein System zur Unfallfolgenverminderung durch autonomes Notbremsen zu entwickeln. Bei längeren Prädiktionsdauern im Bereich von mehreren Sekunden ist es jedoch kaum noch möglich, eine Aussage über die Gefährlichkeit einer Szene zu treffen, da die physikalisch möglichen Trajektorien einen zu großen Bereich abdecken.

Dem gegenüber verfolgen Broadhurst et. al. in [BBK04] das Ziel, einen möglichst sicheren Pfad durch eine Szene zu finden. Hierfür wird der Raum der Eingänge \mathcal{U} diskretisiert und als Entscheidungsbaum repräsentiert. In diesem Baum kann mit Methoden der dynamischen Programmierung ein optimaler Pfad an Kontrollsequenzen zur Navigation durch die Szene bestimmt werden. Bei diesem Vorgehen werden jedoch ungünstige Pfade sehr schnell eliminiert, weshalb auf diese Weise keine Integration von Gleichung (4.2) vorgenommen werden kann und es damit auch nicht möglich ist, Kollisionswahrscheinlichkeiten anzugeben. Um dennoch Aussagen über Kollisionswahrscheinlichkeiten treffen zu können, kann Gleichung (4.2) durch Monte-Carlo-Sampling approximiert werden [BBK05]. Auch diese Art der Bestimmung einer Kollisionswahrscheinlichkeit ist sehr rechenaufwändig. Eidehall und Petersson entwickeln den Ansatz in [EP08] weiter, indem sie ein iteratives Sampling anwenden, das mit einer kleineren Anzahl von Samples den Raum der möglichen Trajektorien besser abdeckt. Die grundsätzliche Schwierigkeit bleibt jedoch bestehen.

Als weitere Herausforderung kommt die Tatsache zum Tragen, dass nicht alle Systemeingänge gleich wahrscheinlich sind, sondern die zu erwartenden Steueranöver des Fahrers stark von seiner aktuellen Absicht auf taktischer und operationeller Ebene abhängen. Die Bildung dieser Absicht basiert auf dem vom Fahrer erkannten aktuellen Kontext, in dem sich das Fahrzeug bewegt und kann durchaus auf einer Fehleinschätzung eines oder mehrerer Fahrer beruhen.

In Prädiktionssystemen wird meist in Ermangelung von Informationen über Fahrerabsichten davon ausgegangen, dass das Fahrzeug sich in naher Zukunft gleichförmig weiterbewegen wird. Die Annahme, dass Fahrzeuge beständig weiter geradeausfahren, ist besonders bei beginnenden Fahrmanövern in Kreuzungen und bei Fahrstreifenwechseln (und damit gerade während Unfallschwerpunkten) verletzt. Andererseits wird der Raum der über den Kammschen Kreis ermittelbaren physikalisch möglichen Fahrtrajektorien über mehrere Sekunden hinweg so groß, dass kaum noch Aussagen getroffen werden können. Deshalb stehen alle Verfahren zur mehrsekündigen Prädiktion und Bewertung vor der Herausforderung, den Bewegungshorizont der einzelnen Fahrzeuge so einzuschränken, dass das Szenario handhabbar wird, aber relevante Verkehrssituationen abgedeckt sind.

In [BBK05] wird versucht, dies über unterschiedliche Gewichtungen von Eingängen im Zustandsraum \mathcal{U} zu berücksichtigen. Die Wahl dieser Gewichte ohne ausreichend Kontextinformation fällt jedoch schwer. Anstatt auf den dynamischen Zustand wird in [WBF⁺13] auf die Orientierung von erfassten Objekten zurückgegriffen, um diese zu präzisieren. Dies soll vor allem bei einer Einschätzung von statischen Objekten, die im Kreuzungsumfeld stehen und losfahren könnten, helfen.

Im vorliegenden Kapitel wird auf das in dieser Arbeit vorgestellte System zur Fahrerabsichtserkennung (Kapitel 3) verwiesen, das den benötigten Kontext für eine Gefährlichkeitsabschätzung mit einem Zeithorizont von mehreren Sekunden liefern kann.

4.1.2 Zeitliche Gewichtung

Die akute Gefährlichkeit einer zu erwartenden Objektkonstellation wird maßgeblich dadurch bestimmt, wie weit diese in die Zukunft prädictiert wurde. Zu erwartende Kollisionen in fernerer Zukunft sind prinzipiell weniger kritisch, da einerseits noch genügend Zeit zum Reagieren bleibt und andererseits mit zunehmendem Prädiktionshorizont auch die Fehler bei der Prädiktion selbst größer werden, und getroffene Annahmen stärker ins Gewicht fallen.

Während bei deterministischer Prädiktion verschiedene skalare Zeitmaße Verwendung finden, erhält man bei probabilistischer Prädiktion einen Zeitverlauf.

4.1.2.1 Zeitliche Kenngrößen bei deterministischer Prädiktion

Das Standardmaß zur Bewertung deterministisch prädizierter Trajektorien ist die verbleibende Zeit bis zur Kollision TTC (engl. Time To Collision, z. B. [Dag05; DMSS04; HKS05; PTA⁺04]). Diese bezeichnet den frühesten Zeitpunkt, an dem eine Kollision basierend auf den getroffenen Annahmen und Modellen stattfinden wird, also die minimale Zeit, bei der die Kollisionswahrscheinlichkeit den Wert 1 annimmt – falls es einen Zeitpunkt gibt, an dem die Kollisionswahrscheinlichkeit diesen Wert annimmt. Im anderen Fall, wenn also die Fahrzeuge sich nicht auf Kollisionskurs bewegen, wird dieses Maß unendlich.

$$TTC = \begin{cases} \min(t) \mid P_t(\mathcal{C}) = 1 & \text{falls } \exists t \mid P_t(\mathcal{C}) = 1 \\ \infty & \text{sonst} \end{cases} \quad (4.3)$$

Im einfachsten Fall einer Kollision bei Prädiktion mit konstanter Geschwindigkeit und konstantem Gierwinkel erhält man die Zeit direkt aus Relativdistanz d_r und Relativgeschwindigkeit der beiden Objekte v_r . Mit der Definition der Relativgeschwindigkeit als Veränderung der Relativdistanz

$$v_r = \frac{dd_r}{dt} \quad (4.4)$$

ergibt sich für den Kollisionsfall eine negative Relativgeschwindigkeit und damit eine positive Zeitgröße TTC als

$$TTC = -\frac{d_r}{v_r}. \quad (4.5)$$

Dieses Maß deckt nur Kollisionen ab und wird unendlich für gefährliche Fahrtrajektorien, die nur beinahe in einer Kollision resultieren. Es haben sich jedoch noch andere Kenngrößen verbreitet, die dieser Limitierung nicht unterliegen. Nennenswert sind insbesondere die zu erwartende minimale Distanz PMD (engl. Predicted Minimum Distance) zwischen zwei Objekten und die Zeit, bis diese minimale Distanz erreicht wird (TPMD, engl. Time to Predicted Minimum Distance).

Andere Kenngrößen zielen auf die Zeit ab, die dem Fahrer noch verbleibt, um durch angemessene Reaktion eine gefährliche Situation zu entschärfen. Erfolgt die Reaktion durch eine Bremsung oder Beschleunigung, wird von TTB (engl. Time To Brake) bzw. TTK (engl. Time To Kickdown) gesprochen; die verbleibende Zeit bis zu einem Lenkmanöver wird durch TTS (Time To Steer) bezeichnet. Die längere der drei Zeiten wird als insgesamt verbleibende Reaktionszeit TTR bezeichnet, da alle drei

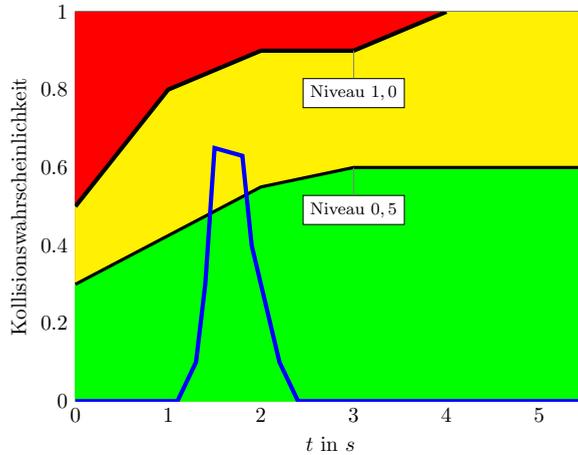


Abbildung 4.1: Beispielhafte Darstellung einer Schablone zur zeitlichen Gewichtung einer Kollisionswahrscheinlichkeit. Je nach Prädiktionshorizont kann eine Kollisionswahrscheinlichkeit (blau) eine unterschiedliche Gefährdung bewirken.

Zeiten Optionen darstellen, die gefährliche Situation zu entschärfen [HKS05; HSK06].

$$TTR = \max(TTB, TTK, TTS) \quad (4.6)$$

Als Oberbegriff der verschiedenen zeitlichen Kenngrößen dient die Abkürzung TTX (Time to X).

Die effiziente Berechnung von zeitlichen Kenngrößen bleibt Gegenstand von Forschung und Entwicklung [TDB11]. Um Unsicherheiten bei Objektdetektion, Tracking und Prädiktion auch bei Gefährlichkeitsbetrachtungen berücksichtigen zu können, rücken jedoch probabilistische Ansätze immer mehr in den Vordergrund.

4.1.2.2 Zeitliche Kenngrößen bei probabilistischer Prädiktion

Im Falle einer probabilistischen Prädiktion verallgemeinert sich die eindimensionale Zeitbetrachtung zu einem zweidimensionalen Ansatz, der jedem prädizierten Zeitpunkt eine Kollisionswahrscheinlichkeit zuordnet. Aus dem skalaren Wert der TTC wird so eine Kurve der Kollisionswahrscheinlichkeit über der Zeit $P_t(C)$.

Abb. 4.1 zeigt ein Beispiel eines Kollisionswahrscheinlichkeitsverlaufs (blaue Kurve).

Mertz hat vorgeschlagen, über den Verlauf der Kollisionswahrscheinlichkeit über der Zeit eine Schablone mit unterschiedlichen farblich kodierten Warnstufen zu legen [MDG⁺05; Mer04]. So kann beispielsweise ein Kurvenverlauf im grünen Bereich in Abb. 4.1 bedeuten, dass keine Warnung notwendig ist. Das Schneiden der Kurve durch den gelben oder roten Bereich kann durch unterschiedliche Dringlichkeit einer Warnung repräsentiert werden. Damit kann dem zeitlichen Aspekt der Gefährdung Rechnung getragen werden.

Die farblichen Bereiche sind gut zur Auswahl diskreter Warnstrategien geeignet. Wird am Ausgang des Systems zur Gefahrenbewertung jedoch ein skalarer Wert erwartet, beispielsweise um die Gefährlichkeit unterschiedlicher Situationen vergleichen zu können, muss die Kurve auf einen solchen kondensiert werden. An dieser Stelle wird vorgeschlagen, die Schablonen von Mertz zu erweitern, indem den Trennlinien der farblichen Bereiche jeweils ein Niveau zugewiesen wird. Interpoliert man die Kollisionswahrscheinlichkeit linear zwischen den Niveaus, erhält man zu jedem Zeitpunkt einen zeitlich gewichteten skalaren Gefahrenwert. Die Gesamtgefährdung, die beispielsweise an eine Mensch-Maschine-Schnittstelle weitergegeben werden kann, ergibt sich aus dem Maximum der einzelnen Gefahrenwerte. Diese können gegebenenfalls aus der Betrachtung von mehreren potentiellen Kollisionsgegnern im aktuellen Umfeld berechnet werden.

Ein alternativer Ansatz zur Einbringung von Unsicherheit in die zeitlichen Kenngrößen besteht darin, anstatt der Kollisionswahrscheinlichkeit über der Zeit die Verteilung der TTX zu beschreiben [BTDB11; BTDB12]. In diesem Fall wird die Wahrscheinlichkeit, dass die betreffende zeitliche Kenngröße TTX früher als zum Zeitpunkt t erreicht wird, ausgewertet. Ein System würde beispielsweise auslösen, wenn diese Wahrscheinlichkeit eine gewisse Konfidenz P_{conf} übertrifft.

$$P(TTX < t) > P_{conf} \quad (4.7)$$

Aufgrund der größeren Anschaulichkeit wird im Folgenden der Ansatz des zeitlichen Verlaufs der Kollisionswahrscheinlichkeit gewählt. Der Fokus liegt dabei auf effizienten Näherungslösungen für die Kollisionswahrscheinlichkeit zu einem gegebenen Zeitpunkt in Abhängigkeit von der Prädiktionsunsicherheit.

4.2 Annahmen

Es seien prädizierte Trajektorien für zwei Objekte gegeben. Unter *Kollisionswahrscheinlichkeitsverlauf* $P_t(\mathcal{C})$ wird eine Funktion verstanden, die jedem Zeitpunkt die Wahrscheinlichkeit zuweist, dass die Objekte auf diesen Trajektorien zu diesem Zeit-

punkt miteinander kollidieren. Bei einer kontinuierlichen Darstellung der prädierten Trajektorien wäre auch der Kollisionswahrscheinlichkeitsverlauf eine kontinuierliche Funktion. Entsprechend wird bei Verwendung einer zeitlich diskretisierten Prädiktion auch der Kollisionswahrscheinlichkeitsverlauf in diskretisierter Form angegeben.

Einzelne Aufenthaltsorte von Objekten werden als zweidimensionale *Position* $[x, y]^T$ beschrieben. Da probabilistisch kontinuierlich modellierte Punkte jedoch nie miteinander kollidieren würden, kommt bei Kollisionsbetrachtungen den Objektdimensionen eine entscheidende Bedeutung zu.

Das Objekt selbst wird als rechteckige Box modelliert, deren Mittelpunkt an der angegebenen Position liegt. Die Objektbox ist um den Gierwinkel ψ verdreht.

Die Positionskordinaten des Mittelpunktes sowie die Ausrichtung ψ sind variabel und Unsicherheiten unterworfen. Der unsichere Zustandsvektor ergibt sich zu $\mathbf{x} = [x, y, \psi]$. Die Unsicherheit wird durch Wahrscheinlichkeitsdichtefunktionen f beschrieben. Diese Funktionen sind das Ergebnis der Prädiktion, und i.Allg. zeitabhängig. Sie sind das Ergebnis einer Prädiktion, und werden im Rahmen der Kollisionsbewertung als gegeben angenommen.

Breite b und Länge l des Rechtecks der Objektausdehnung werden als fest und deterministisch angenommen. Dabei liegt die Annahme zu Grunde, dass Unsicherheiten in der Breiten- und Längenschätzung vernachlässigbar gegenüber den Positions- und Ausrichtungsunsicherheiten bei einer mehrsekündigen Prädiktion sind.

Aufenthaltsorte und Orientierungen der beiden Fahrzeuge werden im Rahmen der Gefährlichkeitsbewertung als stochastisch voneinander unabhängige Ereignisse angenommen. Obwohl Fahrzeuge im Straßenverkehr miteinander interagieren und sich keinesfalls unabhängig voneinander bewegen, stellt diese Annahme für die Methodik der Gefahrenbewertung keine signifikante Einschränkung dar. Es wird davon ausgegangen, dass Interaktionen zwischen den Fahrzeugen bereits in die Trajektorienprädiktion selbst eingeflossen sind und nicht erst bei der Bewertung dieser Trajektorien berücksichtigt werden.

4.3 Bestimmung von Kollisionswahrscheinlichkeiten bei deterministischer Prädiktion

Werden zusätzlich zu den Objektdimensionen auch die Trajektorien deterministisch modelliert, kann die Kollisionswahrscheinlichkeit zu jedem Zeitpunkt sicher angegeben werden.

$$P_t(C) = \begin{cases} 1 & \text{falls die Objektboxen zum Zeitpunkt } t \text{ überlappen} \\ 0 & \text{sonst} \end{cases} \quad (4.8)$$

Da jedoch in der Realität nicht davon ausgegangen werden kann, dass der dynamische Zustand von Objekten bei einer Prädiktionsdauer von mehreren Sekunden mit hinreichender Genauigkeit angegeben werden kann, bieten probabilistische Verfahren Vorteile.

4.4 Bestimmung von Kollisionswahrscheinlichkeiten bei Prädiktion mittels Wahrscheinlichkeitsverteilungen

Die probabilistischen Aufenthaltsorte der beiden Objekte seien als multivariate Wahrscheinlichkeitsdichtefunktionen f_1 und f_2 gegeben. Die Objekte selbst werden wie in Abschnitt 4.2 beschrieben als Boxen mit fester Breite und Länge angenommen. Der Zustandsraum besteht aus Ort und Orientierung $\mathbf{x} = [x, y, \psi]^T$ dieser Objektboxen. Der gesamte Zustandsraum sei mit Ω bezeichnet.

Zunächst soll eine geschlossene Darstellung der Kollisionswahrscheinlichkeit einer Objektkonstellation zu einem einzelnen festgelegten Zeitpunkt hergeleitet werden. Um den gesamten Verlauf der Kollisionswahrscheinlichkeit über der Zeit zu erhalten, müssen die folgenden Berechnungen also für jeden Zeitpunkt separat ausgeführt werden. In diesem Fall muss die zusätzliche Zeitabhängigkeit der Dichtefunktionen f_1 und f_2 berücksichtigt werden, die z. B. als Ergebnis einer Prädiktion erhalten werden.

Es sei \mathbf{v}_1 ein infinitesimal kleiner Bereich im Zustandsraum, an dem sich das erste Fahrzeug aufhält. Dann kann, basierend auf den bekannten Objektdimensionen, derjenige Bereich \mathbf{V} im Zustandsraum bestimmt werden, an dem sich das zweite

Fahrzeug aufhalten muss, um mit dem ersten Fahrzeug zu kollidieren. Die Definition des Bereichs \mathbf{V} muss also gerade so erfolgen, dass eine Kollision sicher ist unter der Bedingung, dass die beiden Objekte sich in den entsprechenden Bereichen des Zustandsraums aufhalten.

$$P(\mathcal{C} | \mathbf{x}_1 \in \mathbf{v}_1, \mathbf{x}_2 \in \mathbf{V}) = 1 \quad (4.9)$$

Aufgrund der ebenfalls in Abschnitt 4.2 beschriebenen Annahme der Unabhängigkeit der Objektzustände lässt sich die Verbundwahrscheinlichkeit der Aufenthaltsorte beider Fahrzeuge als Produkt der Einzelwahrscheinlichkeiten angeben.

$$P(\mathbf{x}_1 \in \mathbf{v}_1, \mathbf{x}_2 \in \mathbf{V}) = P(\mathbf{x}_1 \in \mathbf{v}_1) \cdot P(\mathbf{x}_2 \in \mathbf{V}) \quad (4.10)$$

Die Wahrscheinlichkeiten, dass die Fahrzeuge sich in den jeweiligen Bereichen aufhalten, erhält man durch Integration der multivariaten Wahrscheinlichkeitsdichtefunktion f über den jeweiligen Bereich des dreidimensionalen Zustandsraums. Für das erste Fahrzeug ergibt sich

$$P(\mathbf{x}_1 \in \mathbf{v}_1) = \int_{\mathbf{v}_1} f_1 d\mathbf{v}_1. \quad (4.11)$$

Da der Kollisionsbereich \mathbf{V} für das zweite Fahrzeug i.Allg. nicht zusammenhängend sein muss, teilt man ihn zweckmäßig in n_b disjunkte Teilbereiche \mathbf{V}_i auf.

$$\mathbf{V} = \bigcup_{i=1}^{n_b} \mathbf{V}_i \quad (4.12)$$

Damit ergibt sich für das zweite Fahrzeug

$$P(\mathbf{x}_2 \in \mathbf{V}) = \int_{\mathbf{V}} f_2 d\mathbf{V} = \sum_{i=1}^{n_b} \int_{\mathbf{V}_i} f_2 d\mathbf{V}_i. \quad (4.13)$$

Nach dem Gesetz der totalen Wahrscheinlichkeit gilt für die Kollisionswahrscheinlichkeit

$$P(\mathcal{C}) = \sum_{\mathbf{v}_1 \in \Omega} P(\mathcal{C} | \mathbf{x}_1 \in \mathbf{v}_1, \mathbf{x}_2 \in \mathbf{V}) \cdot P(\mathbf{x}_1 \in \mathbf{v}_1, \mathbf{x}_2 \in \mathbf{V}) \quad (4.14)$$

Einsetzen von Gleichungen (4.9), (4.10), (4.11) und (4.13) in (4.14) und Übergang von Summation zur Integration bei Betrachtung eines infinitesimal kleinen Bereichs

\mathbf{v}_1 ergibt

$$P(\mathcal{C}) = \int_{\mathbf{v}_1 \in \Omega} \left(\int_{\mathbf{v}_1} f_1 d\mathbf{v}_1 \cdot \sum_{i=1}^{n_b} \int_{V_i} f_2 dV_i \right) d\mathbf{v}_1. \quad (4.15)$$

Die analytische Berechnung dieses verschachtelten mehrdimensionalen Integrals ist selbst für einfache Verteilungen f sehr schwierig. Eine mögliche Näherung wäre die Berechnung mit Monte-Carlo-Integration. Dies würde die Schwierigkeit, eine Stammfunktion zu finden, vermeiden. Allerdings wäre die Berechnung des Integrals noch immer sehr kompliziert, da komplexe Bereichsgrenzen \mathbf{V}_i ermittelt werden müssen. Im Folgenden wird statt des Versuchs der Lösung von (4.15) auf alternative Ansätze eingegangen.

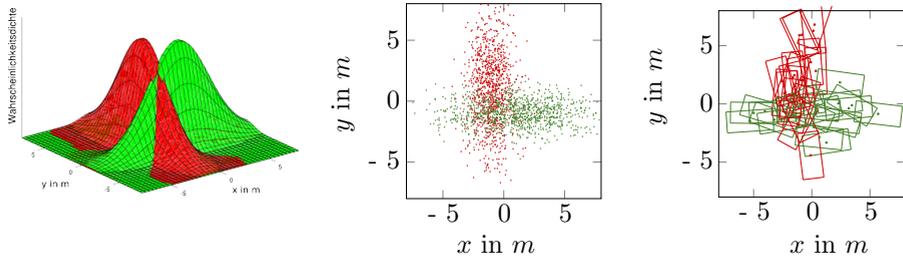
4.5 Annäherung mit Monte-Carlo-Sampling

Eine einfachere Möglichkeit der Annäherung der Kollisionswahrscheinlichkeit ohne explizite Berechnung von Gleichung (4.15) besteht darin, zufällig eine Menge an Realisierungen gemäß der Verteilungsfunktionen f_1 und f_2 zu erzeugen und direkt eine Monte-Carlo-Auswertung durchzuführen. Nach dem Gesetz der Großen Zahlen nähert sich die relative Häufigkeit bei einer großen Anzahl von Elementen n der exakten Kollisionswahrscheinlichkeit an. Der Aufwand wächst jedoch quadratisch mit der Anzahl der Elemente, was in praktischen Anwendungsfällen die erreichbare Genauigkeit beschränkt. Andererseits sind Monte-Carlo-Verfahren durch ihre sehr gute Parallelisierbarkeit und das zunehmende Aufkommen von hochgradig parallel arbeitenden Rechnerarchitekturen in automotiven Anwendungen [HKOB10] eine interessante Möglichkeit mit der Option, direkt einen Kompromiss zwischen zu erwartender Genauigkeit und verfügbarer Rechenleistung auswählen zu können.

In Abbildung 4.2 ist beispielhaft der zukünftige Zustand zweier Objekte als Normalverteilungen gegeben. Aus den parametrischen Verteilungen (a) wird zufällig eine Anzahl an Realisierungen (b) gezogen. Dann wird zu jeder Realisierung die zugehörige Objektbox gebildet (c) und per Überlappungstest ausgewertet.

Aus Darstellungsgründen wurde die Wahrscheinlichkeitsdichtefunktion in den Abbildungen (a) und (b) auf zwei Dimensionen beschränkt. Zusätzlich zur Position ist auch die Orientierung der Verteilung unterworfen, wie man an den nicht achsparallel ausgerichteten Objektboxen in (c) sieht.

Zur Bestimmung der Kollisionswahrscheinlichkeit wird jedes Sample des ersten Ob-



(a) Normalverteilungen (b) Zufällig gezogene Samples (c) Einige Objektboxen

Abbildung 4.2: Monte-Carlo-Auswertung der Kollisionswahrscheinlichkeit eines als Normalverteilung gegebenen Paares von Aufenthaltsorten zweier Objekte.

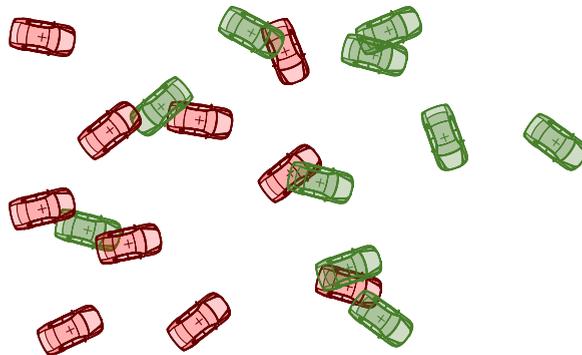


Abbildung 4.3: Monte-Carlo-Abschätzung einer Kollisionswahrscheinlichkeit. Jedes Sample des grünen Fahrzeugs wird gegen jedes Sample des roten Fahrzeugs auf Überlappung getestet.

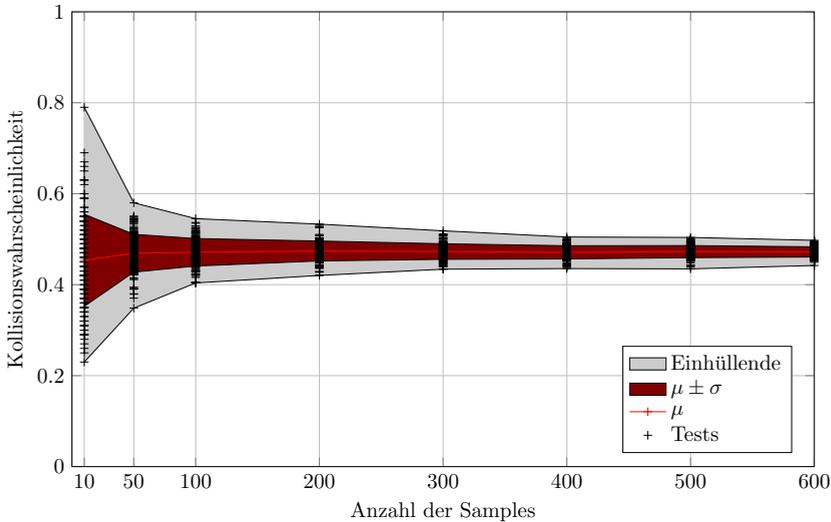


Abbildung 4.4: Wiederholgenauigkeit einer Monte-Carlo-Simulation in Abhängigkeit der Anzahl der Samples am Beispiel einer mittleren Kollisionswahrscheinlichkeit.

jekts mit jedem Sample des zweiten Objekts auf Überlappung geprüft und deren Anzahl gezählt. Bei n Elementen pro Menge und n_c Kollisionen ergibt sich die Kollisionswahrscheinlichkeit angenähert als relative Häufigkeit des Kollisionsereignisses.

$$P(\mathcal{C}) \approx h_c(t_i) = \frac{n_c}{n^2} \quad (4.16)$$

Abbildung 4.3 zeigt ein Beispiel mit zehn Elementen. Vier der zehn grünen Fahrzeuge überlappen mit keinem roten Fahrzeug, vier überlappen mit je einem roten Fahrzeug und bei zwei Samples gibt es jeweils zwei Überlappungen. In diesem Beispiel ergäbe sich also eine relative Kollisionshäufigkeit von 8 %. Um von einer angenäherten Wahrscheinlichkeit sprechen zu können, müsste allerdings die Zahl der Elemente bedeutend höher sein. Im Beispiel aus Abb. 4.2 ergibt sich eine angenäherte Kollisionswahrscheinlichkeit von etwa 30 %.

Da die Rechenzeit quadratisch mit der Anzahl der gezogenen Samples wächst, möchte man diese Zahl möglichst niedrig halten. Abbildung 4.4 zeigt beispielhaft die wiederholte Auswertung der Kollisionswahrscheinlichkeit einer Objektkonfiguration. Mit zunehmender Anzahl von Samples wird wie erwartet die Streuung der geschätzten Wahrscheinlichkeit immer geringer. Allerdings werden Anzahlen von etwa 300 Samples benötigt, um den Einfluss der zufälligen Auswahl der Samples klein zu halten und

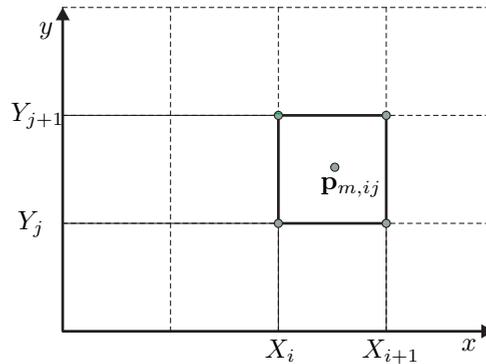


Abbildung 4.5: Bezeichnungen im diskretisierten Raster

nicht Gefahr zu laufen, selbst mit Monte-Carlo-Simulation schlechte Ergebnisse zu liefern.

4.6 Grid-Ansatz zur Bestimmung von Kollisionswahrscheinlichkeiten über Faltungsoperatoren

Alternativ zum Monte-Carlo-Sampling kann die Kollisionswahrscheinlichkeit durch Auswertung von Rasterkarten-basierenden Ansätzen angenähert werden. Dazu wird eine Belegungskarte erzeugt. Der Wert einer Zelle beschreibt, mit welcher Wahrscheinlichkeit die Zelle zum jeweiligen Prädiktionszeitpunkt mit einem Objekt belegt ist. Eine Kollision findet dann statt, wenn mindestens eine Zelle von mehr als einem Objekt gleichzeitig besetzt wird.

Abb. 4.5 zeigt die Benennung der Zellen im Raster. Die Zelle mit dem Index ij liegt zwischen den Spaltengrenzen X_i und X_{i+1} sowie den Zeilengrenzen Y_i und Y_{i+1} . Der Mittelpunkt der Zelle wird mit $\mathbf{p}_{m,ij}$ bezeichnet.

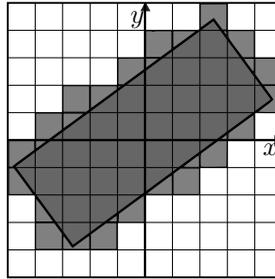


Abbildung 4.6: Schematische Darstellung eines Faltungskerns für die Objektdimension ohne Berücksichtigung der Orientierungsunsicherheit. Zellen, die ganz oder teilweise von der Objektbox überlappt werden, werden im Faltungskern als belegt gekennzeichnet.

4.6.1 Aufenthaltswahrscheinlichkeit des Fahrzeugmittelpunktes in jeder Zelle

Der erste Schritt auf dem Weg zur Angabe der Kollisionswahrscheinlichkeit ist die Auswertung, mit welcher Wahrscheinlichkeit die Position des jeweiligen Objekts in der betreffenden Zelle liegt. Die Betrachtung bezieht sich also noch nicht auf die Belegungswahrscheinlichkeit der Zelle durch das ausgedehnte Objekt, sondern auf die Wahrscheinlichkeit, dass sich der Mittelpunkt des Objekts in der Zelle befindet.

Für den Fall, dass die Aufenthaltswahrscheinlichkeit des Fahrzeugs parametrisch gegeben ist, kann die gesuchte Wahrscheinlichkeit durch Integration der Wahrscheinlichkeitsdichtefunktion f über die Zellenfläche oder durch Auswerten der kumulativen Verteilungsfunktion F gefunden werden. Mit der Darstellung der Zelle ij als zweidimensionalem Intervall $I_{ij} = [X_i, X_{i+1}] \times [Y_j, Y_{j+1}]$ ergibt sich

$$P(\mathbf{p} \in I_{ij}) = \int_{Y_j}^{Y_{j+1}} \int_{X_i}^{X_{i+1}} f(x, y) dx dy \quad (4.17)$$

$$P(\mathbf{p} \in I_{ij}) = F(X_{i+1}, Y_{j+1}) - F(X_i, Y_{j+1}) - F(X_{i+1}, Y_j) + F(X_i, Y_j) \quad (4.18)$$

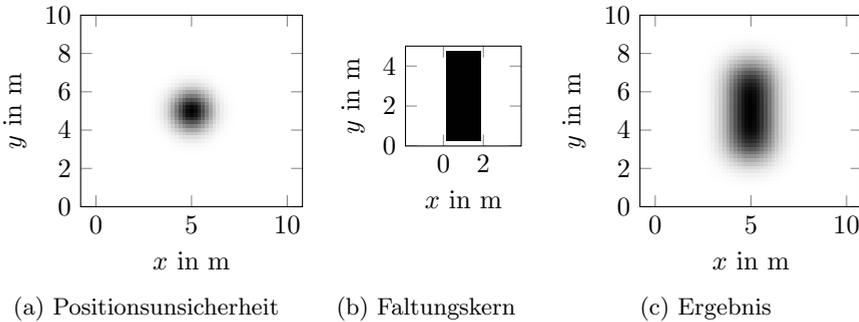


Abbildung 4.7: Faltung der Positionsunsicherheit (a) mit der Fahrzeugdimension (b) zum Erhalt eines Grids der Belegungswahrscheinlichkeit (c)

4.6.2 Berücksichtigung der räumlichen Ausdehnung und der Orientierung der Fahrzeuge

Da Fahrzeuge eine räumliche Ausdehnung haben, ist nicht nur die Gitterzelle der Objektposition belegt, sondern auch ein umliegender Bereich an Zellen entsprechend Fahrzeugdimension und Ausrichtung. Die Modellierung dieser Belegung geschieht durch Faltung der Wahrscheinlichkeitsdichtefunktion der Objektposition mit einem Faltungskern, der die Ausdehnung und Orientierung des Fahrzeuges einbringt.²

Abb. 4.6 zeigt eine schematische Darstellung des Faltungskerns. Er besteht aus einem Grid, das gerade groß genug ist, das entsprechend verdrehte Fahrzeug zu fassen. In dem Grid werden alle Zellen, die ganz oder teilweise vom Fahrzeug überdeckt sind, mit dem Wert eins belegt. Freie Zellen erhalten den Wert null. Wie in den Annahmen beschrieben, bezieht sich die Position eines Objektes in diesem Kapitel auf den Mittelpunkt der Objektbox, der deshalb im Grid des Faltungskerns in den Ursprung gelegt wird. Die Zellengröße des Faltungskerns entspricht der des ursprünglichen Rasters. Die Kantenlänge des Grids ist ein Design-Parameter, und stellt einen Kompromiss zwischen Rechenaufwand und Diskretisierungsfehler dar. Im vorliegenden Fall wurde eine Kantenlänge von 20 cm gewählt. Die schematische Darstellung aus Abb. 4.6 ist aus anschaulichen Gründen mit deutlich groberer Rasterung erstellt worden.

Ein Beispiel für eine durch Faltung erhaltene Aufenthaltswahrscheinlichkeit ist in Abb. 4.7 gezeigt. Links ist die Positionsunsicherheit als Grauwertbild dargestellt. Im Beispiel besteht diese aus einer diskretisierten zweidimensionalen Normalverteilung.

²Siehe auch [Mun11] für ein ähnliches Vorgehen in anderem Kontext.

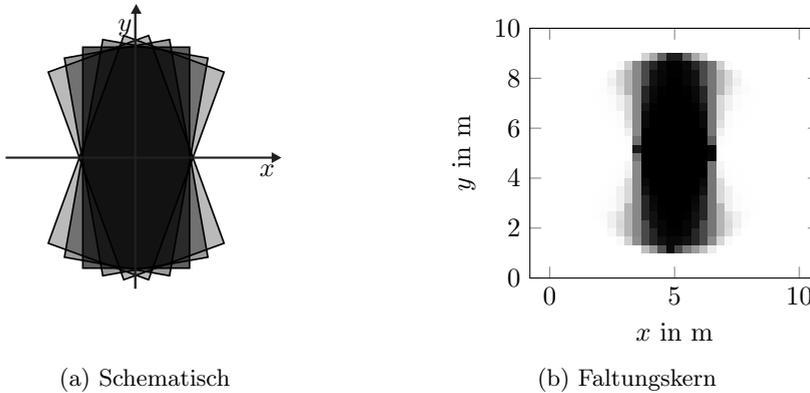


Abbildung 4.8: Links: Schematische Darstellung der Überlagerung von entsprechend der Orientierungswahrscheinlichkeit gewichteten Objektboxen. Rechts: Beispiel eines resultierenden Faltungskerns.

Durch Faltung mit einem Kern, der die Fahrzeugdimensionen berücksichtigt (Mitte) und anschließende Normierung auf einen Integralwert von eins, erhält man ein Grid für die Belegungswahrscheinlichkeit jeder Zelle mit dem Fahrzeug. Man sieht, wie die Unsicherheitsverteilung der Position entsprechend der Fahrzeugdimension wie erwartet aufgeweitet wird.

4.6.3 Berücksichtigung der Unsicherheit der Orientierung

Durch die beschriebene Faltung werden Unsicherheiten in der Orientierung vernachlässigt. Diese können ebenfalls im Faltungskern berücksichtigt werden. Dazu wird der Winkelbereich um den Schätzwert des Gierwinkels gerastert. Entsprechende Objektboxen werden mit ihrem jeweiligen Wahrscheinlichkeitsanteil gewichtet überlagert, das Ergebnis wird wieder so normiert, dass im Ursprung der Wert eins erreicht wird. Abb. 4.8 zeigt ein Beispiel in der schematischen Darstellung (links) sowie als diskretisierten Faltungskern (rechts). Mit diesem Kern wird sowohl die Objektdimension als auch die Orientierungsunsicherheit berücksichtigt.

Die so erhaltene Belegungswahrscheinlichkeit der Zelle ij durch das Fahrzeug k wird im Folgenden mit $P_b^{(k)}(ij)$ bezeichnet.

4.6.4 Berechnung einer Kollisionswahrscheinlichkeit

Wurde das beschriebene Vorgehen zum Erhalt von Belegungswahrscheinlichkeiten pro Rasterzelle für zwei Fahrzeuge durchgeführt, kann eine Kollisionswahrscheinlichkeit für diese beiden Fahrzeuge zum entsprechenden Zeitpunkt angenähert werden.

In einer einzelnen Zelle ij kommt es zu einer Kollision, wenn diese gleichzeitig durch beide Fahrzeuge belegt wird. Bei angenommener stochastischer Unabhängigkeit gilt

$$P(\mathcal{C})|_{ij} = P_b^{(1)}(ij) \cdot P_b^{(2)}(ij) \quad (4.19)$$

Zu einer Kollision der Fahrzeuge kommt es, wenn in mindestens einer Zelle eine Kollision stattgefunden hat. Um zu einer Aussage über die Kollisionswahrscheinlichkeit der Fahrzeugkonstellation insgesamt zu kommen, müssen die Belegungswahrscheinlichkeiten der Einzelzellen verrechnet werden.

Ein einfacher Ansatz zur Berechnung eines Kollisionsmaßes besteht in einer *oder*-Verknüpfung der Kollisionsereignisse in den einzelnen Zellen. Als Maß kann die Summe der Kollisionswahrscheinlichkeiten in den einzelnen Zellen $\mathcal{L}(\mathcal{C})$ genutzt werden. Dieser Wert kann als Zählwert für Kollisionsereignisse aufgefaßt werden. Er ist seinerseits allerdings keine Wahrscheinlichkeit, da Kollisionen in Einzelzellen keine disjunkten Ereignisse sind.³ Mit n_I und n_J als Anzahl der Spalten bzw. Zeilen im Gitter ergibt sich

$$\mathcal{L}(\mathcal{C}) = \sum_{i=0}^{n_I} \sum_{j=0}^{n_J} P(\mathcal{C})|_{ij}. \quad (4.20)$$

Eine alternative Berechnung geht vom Komplementärereignis $\bar{\mathcal{C}}$, dass in keinem der Zellen eine Kollision stattfindet, aus.

$$P(\bar{\mathcal{C}}) = \prod_{i=0}^{n_I} \prod_{j=0}^{n_J} (1 - P(\mathcal{C})|_{ij}) \quad (4.21)$$

Die gesuchte Kollisionswahrscheinlichkeit ergibt sich wiederum als Komplementärerereignis.

$$P(\mathcal{C}) = 1 - P(\bar{\mathcal{C}}) \quad (4.22)$$

³Dies ist durch ein Beispiel leicht ersichtlich: Wenn in zwei Zellen jeweils eine sichere Kollision vorliegt, ergibt sich ein Wert von $\mathcal{L}(\mathcal{C}) \geq 2$.

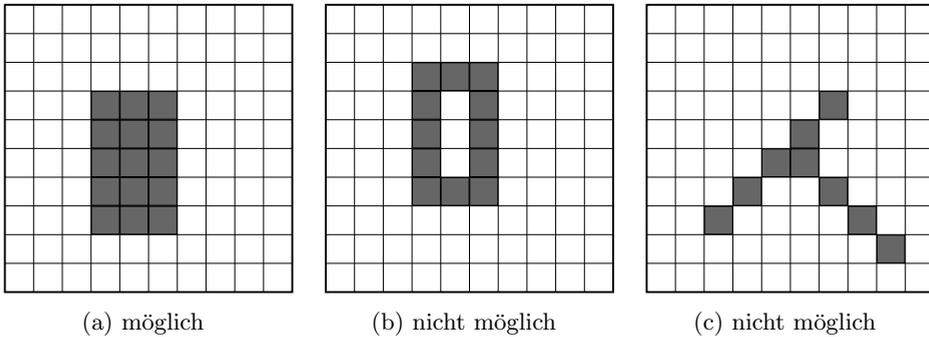


Abbildung 4.9: Graue Zellen bezeichnen ein Kollisionsereignis in der entsprechenden Zelle. Die Menge der physikalisch möglichen Kollisionsereignisse der Einzelzellen ist konvex. Die Beispiele aus (b) und (c) werden zwar mitgezählt, sind aber keine physikalisch möglichen Kombinationen.

An dieser Stelle ist eine weitere Vereinfachung eingeflossen. Es wird implizit angenommen, dass Kollisionen in den einzelnen Zellen unabhängig voneinander sind. Auch wenn die Zustände der Fahrzeuge als stochastisch unabhängig voneinander angenommen wurden, ist diese zusätzliche Annahme verletzt. Da die Überlappung zweier Objektboxen (oder allgemeiner: die Schnittmenge zweier beliebiger konvexer Flächen) eine konvexe Fläche ist, sind nicht alle Kombinationen von Kollisionsereignissen in Einzelzellen möglich, Abb. 4.9.

4.7 Grid-Ansatz zur Bestimmung von Kollisionswahrscheinlichkeiten über Zustandsdiskretisierung

Anstatt Objektdimensionen, Orientierung und Orientierungsunsicherheit über eine Faltung mit entsprechendem Kern abzubilden, kann dies auch über eine Diskretisierung des Zustandsraums erfolgen.

Dazu wird der Winkelbereich der Ausrichtung im $3\sigma_\psi$ -Bereich um den Erwartungswert in diskrete Intervalle der Größe $2\Delta\psi$ gerastert. Es ergibt sich ein endlicher dreidimensionaler diskreter Zustandsraum, der durch die Mittelpunkte der Gitterzellen ij des örtlichen Rasters sowie durch die diskreten mittleren Winkel im jeweiligen

Winkelbereich k aufgespannt wird:

$$\mathbf{x}(i, j, k) = [x_{m,ij}, y_{m,ij}, \psi_k] \quad (4.23)$$

Die Wahrscheinlichkeit, dass ein gegebener Zustand vorliegt, ergibt sich aus der Integration der Wahrscheinlichkeitsdichte über die Gitterzelle sowie den diskretisierten Winkel.

$$P(\mathbf{x}) = \int_{\psi=\psi_k-\Delta\psi}^{\psi_k+\Delta\psi} \int_{y=Y_i}^{Y_{i+1}} \int_{x=X_i}^{X_{i+1}} f(x, y, \psi) dx dy d\psi \quad (4.24)$$

Für gegebene Zustände der beiden Fahrzeuge $\mathbf{x}^{(1)}$ und $\mathbf{x}^{(2)}$ liegt entweder eine Kollision vor oder nicht.

$$P(\mathcal{C}|\mathbf{x}^{(1)}, \mathbf{x}^{(2)}) = \begin{cases} 1 & \text{falls die Objektboxen für } \mathbf{x}^{(1)} \text{ und } \mathbf{x}^{(2)} \text{ überlappen} \\ 0 & \text{sonst} \end{cases} \quad (4.25)$$

Für diesen diskreten Zustandsraum können nun alle möglichen Kombinationen von Zuständen der beiden potentiellen Kollisionspartner auf Kollision untersucht werden. Die gesuchte Kollisionswahrscheinlichkeit ergibt sich aus der Wahrscheinlichkeit, dass die jeweilige Objektkonstellation eintritt, summiert über den diskretisierten Zustandsraum.

$$P(\mathcal{C}) = \sum_{i,j,k} P(\mathbf{x}^{(1)}) P(\mathbf{x}^{(2)}) P(\mathcal{C}|\mathbf{x}^{(1)}, \mathbf{x}^{(2)}) \quad (4.26)$$

Die Wahrscheinlichkeit $P(\mathcal{C}|\mathbf{x}^{(1)}, \mathbf{x}^{(2)})$ wirkt hier nach Gleichung (4.25) als schaltender Term. Fehler sind neben der Modellbildung ausschließlich durch Diskretisierungsungenauigkeiten und eventuelle numerische Einflüsse zu erwarten.

4.8 Beschränkung des Einflussbereiches

Sowohl das beschriebene Monte-Carlo Verfahren als auch die vorgestellten Grid-Ansätze sind rechenintensiv.⁴

⁴Diese Erwartung wird im Rahmen der Auswertung in Abschnitt 4.11 bestätigt werden.

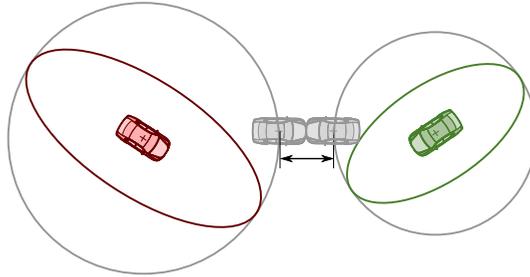


Abbildung 4.10: Wenn die die Unsicherheitsellipsen umschließenden Kreise einen Abstand voneinander haben, der größer ist als die Addition der halben Fahrzeuglängen, ist eine nähere Auswertung der Kollisionswahrscheinlichkeit unnötig.

In vielen Fällen liegen die zu erwartenden Aufenthaltsorte der Objekte so weit auseinander, dass Monte-Carlo-Abschätzungen oder andere rechenintensive Verfahren nicht nötig sind. Es wäre wünschenswert, aufwändige Berechnungen bei der Bewertung der Gefährlichkeit von Trajektorien zu vermeiden.

Im Folgenden sollen effiziente Näherungslösungen für den Spezialfall, dass die probabilistischen Aufenthaltsorte zweier Objekt als multivariate Normalverteilungen

$$\mathbf{x}_1 \sim \mathcal{N}(\mathbf{x}_1; \mu_1, \Sigma_1), \quad \mathbf{x}_2 \sim \mathcal{N}(\mathbf{x}_2; \mu_2, \Sigma_2) \quad (4.27)$$

gegeben sind, betrachtet werden. Dann ergibt sich die Wahrscheinlichkeit des Ereignisses A_i , dass sich das Fahrzeug i in einer $k\sigma$ Ellipse um den Erwartungswert aufhält, als Wert der kumulativen Verteilungsfunktion der χ_3^2 -Verteilung an der Stelle k^2 .

$$P(A_i) = F_{\chi_3^2}(k^2). \quad (4.28)$$

Der Nachweis dieser Beziehung wird in Lemma A.3, Seite 147 geführt.

Die Verbundwahrscheinlichkeit der Ereignisse, dass zwei Fahrzeuge sich innerhalb ihres jeweiligen 3σ Ellipsoiden aufhalten, ergibt sich aufgrund der angenommenen Unabhängigkeit der Ereignisse direkt aus dem Produkt der Einzelwahrscheinlichkeiten.

$$P(A_1, A_2) = \left(F_{\chi_3^2}(k^2) \right)^2 \quad (4.29)$$

Liegen die die Ellipsen umschließenden Kreise weiter auseinander als die Summe der

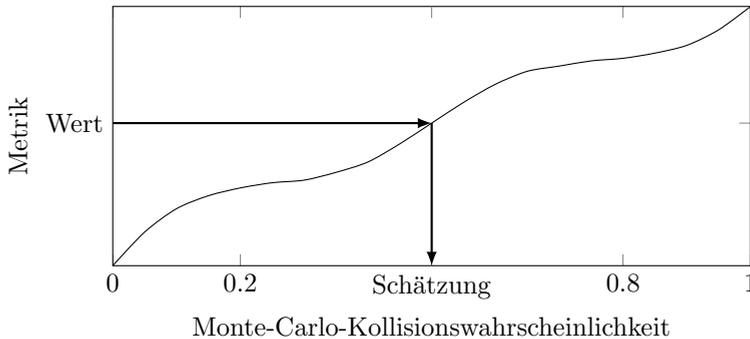


Abbildung 4.11: Schematische Auftragung eines Kollisionsmaßes gegenüber einer Monte-Carlo-Simulation als Referenz. Wenn ein streng monotoner Zusammenhang festgestellt werden kann, ist das Kollisionsmaß als Metrik geeignet.

Hälfte der Fahrzeuglängen (Abb. 4.10), können die Fahrzeuge nicht kollidieren, wenn sich beide in der jeweiligen $k\sigma$ Ellipse befinden. Es lässt sich als obere Schranke eine Kollisionswahrscheinlichkeit von

$$P(\mathcal{C}) < 1 - \left(F_{\chi_3^2}(k^2)\right)^2 \quad (4.30)$$

angeben. Im Falle von 3σ Ellipsen ergibt sich beispielsweise eine obere Schranke von

$$P(\mathcal{C}) < 1 - \left(F_{\chi_3^2}(3^2)\right)^2 \approx 6\%. \quad (4.31)$$

4.9 Abschätzung der Kollisionswahrscheinlichkeit über das Produkt der Wahrscheinlichkeitsdichtefunktionen

Wenn es gelingt, ein einfach zu berechnendes Maß zu finden, das in einem streng monotonen Zusammenhang zur Kollisionswahrscheinlichkeit steht, könnte letztere aus einer Kalibrierkurve erhalten werden. Diese Kurve kann einmalig im voraus bestimmt werden. Als Referenz dient eine große Menge von zufällig ausgewählten Verteilungen, die möglichst den gesamten Bereich von sehr kleinen bis hin zu sehr großen Kollisionswahrscheinlichkeiten abdeckt. Jedes Paar von Verteilungen beschreibt einen Punkt auf der Kalibrierkurve, Abbildung 4.11. Da die Berechnung einmalig und im voraus erfolgt und der Berechnungsaufwand deshalb eine untergeordnete Rolle spielt,

können die Referenzwerte selbst über eine Monte-Carlo-Simulation nach Kapitel 4.5 mit einer hohen Zahl von Elementen bestimmt werden.

Im Folgenden wird gezeigt, wie die Fläche unter dem Produkt von Wahrscheinlichkeitsdichtefunktionen der Positionen als Maß für die Kollisionswahrscheinlichkeit genutzt werden kann.

Es seien zwei zweidimensionale normalverteilte Zufallsvektoren gegeben, die die Positionen von zwei Fahrzeugen repräsentieren.

$$\begin{aligned}\mathbf{x}_1 &\sim \mathcal{N}(\mathbf{x}_1; \mu_1, \Sigma_1) \\ \mathbf{x}_2 &\sim \mathcal{N}(\mathbf{x}_2; \mu_2, \Sigma_2)\end{aligned}$$

Das Produkt der zugehörigen Wahrscheinlichkeitsdichtefunktionen f_1 und f_2 hat die Form einer multivariaten normalverteilten Wahrscheinlichkeitsdichtefunktion.⁵ Mit den Definitionen⁶

$$\mu_p = \Sigma_2 (\Sigma_1 + \Sigma_2)^{-1} \mu_1 + \Sigma_1 (\Sigma_1 + \Sigma_2)^{-1} \mu_2 \quad (4.32)$$

$$\Sigma_p = (\Sigma_1^{-1} + \Sigma_2^{-1})^{-1} \quad (4.33)$$

sowie der Einheitsmatrix \mathbf{I} und den Abkürzungen

$$V_1 = \frac{1}{\sqrt{(2\pi)^2 |\Sigma_1|}} \quad (4.34)$$

$$V_2 = \frac{1}{\sqrt{(2\pi)^2 |\Sigma_2|}} \quad (4.35)$$

$$\begin{aligned}b = V_1 V_2 \cdot \exp \left\{ \frac{1}{2} (\mu_1^T \Sigma_1^{-1} (\Sigma_p \Sigma_1^{-1} - \mathbf{I}) \mu_1 + \right. \\ \left. \mu_2^T \Sigma_2^{-1} (\Sigma_p \Sigma_2^{-1} - \mathbf{I}) \mu_2 + 2\mu_1^T \Sigma_1^{-1} \Sigma_p \Sigma_2^{-1} \mu_2) \right\} \quad (4.36)\end{aligned}$$

ergibt sich

$$f_p = f_1 \cdot f_2 = b \cdot \exp \left\{ -\frac{1}{2} (\mathbf{x} - \mu_p)^T \Sigma_p^{-1} (\mathbf{x} - \mu_p) \right\} \quad (4.37)$$

⁵Der Nachweis gelingt durch direktes Einsetzen und Umformen.

⁶Ein ähnliches Vorgehen findet sich auch bei Ansätzen zur Track-to-Track-Fusion im Objekttracking [BL95].

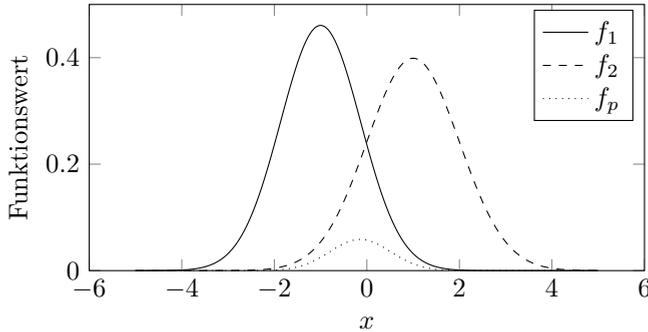


Abbildung 4.12: Beispiel zweier eindimensionaler Dichtefunktionen f_1 und f_2 sowie deren Produkt f_p . Das Produkt kann als Überlappungsmaß genutzt werden.

Abb. 4.12 zeigt ein eindimensionales Beispiel zweier Dichtefunktionen und dem zugehörigen Produkt. Das Produkt hat zwar die Form einer normalverteilten Wahrscheinlichkeitsdichtefunktion, ist aber skaliert. Die Fläche unter der Kurve f_p wird umso größer, je mehr sich die Ausgangsfunktionen überlappen. Die Abbildung wurde aus anschaulichen Gründen auf den eindimensionalen Fall beschränkt. Die Rechnungen im vorliegenden Problem beziehen sich auf die zweidimensionale Fahrzeugposition.

Diese Fläche ist, im Gegensatz zur Kollisionswahrscheinlichkeit, vergleichsweise einfach geschlossen berechenbar. Dabei wird ausgenutzt, dass die Fläche der normierten, nicht-skalierten Version der Kurve bekannt ist. Sei \mathbf{x}_n eine normalverteilte Zufallsvariable mit Mittelwert μ_p und Kovarianz Σ_p .

$$\mathbf{x}_n \sim \mathcal{N}(\mathbf{x}_n; \mu_p, \Sigma_p) \quad (4.38)$$

Die Fläche unter der zugehörigen Dichtefunktion f_n ist normiert.

$$\int_{-\infty}^{\infty} f_n(\mathbf{x}) d\mathbf{x} = 1 \quad (4.39)$$

Aus (4.37) und (4.39) folgt mit der Gleichung für Wahrscheinlichkeitsdichtefunktionen von Normalverteilungen

$$\int_{-\infty}^{\infty} f_p(\mathbf{x}) d\mathbf{x} = b \cdot \sqrt{(2\pi)^2 |\Sigma_p|} \int_{-\infty}^{\infty} f_n(\mathbf{x}) d\mathbf{x}. \quad (4.40)$$

Damit ergibt sich für die Fläche A unter der Kurve des Produkts der Wahrscheinlichkeitsdichtefunktionen

$$A = b \cdot \sqrt{(2\pi)^2 |\Sigma_p|}. \quad (4.41)$$

In dieses Maß sind die Objektdimensionen nicht eingegangen. Diese Vernachlässigung ist nicht in jedem Szenario zielführend. Im Rahmen der Auswertung in Abschnitt 4.11.3 wird gezeigt, unter welchen Bedingungen der Ansatz erfolgversprechend ist.

4.10 Annäherung der Kollisionswahrscheinlichkeit über die Differenz der Positionen

Der folgenden Methode liegt weiterhin die Idee zugrunde, dass der hauptsächliche Einflussfaktor für eine Kollision zweier Fahrzeuge die räumliche Nähe der beiden Objekte ist. Um die Kollisionswahrscheinlichkeit besser anzunähern als im vorhergehenden Abschnitt, müssen jedoch auch die Objektdimensionen berücksichtigt werden.

Die Methode basiert auf dem Ansatz, die Differenz der Positionen als Zufallsvariable zu betrachten anstatt die Positionen der beiden Fahrzeuge getrennt als Zufallsvariablen aufzufassen. Dieser Ansatz wurde von Jansson et. al. [JJG02] angesprochen, ohne jedoch genauer darauf einzugehen. Er soll im Folgenden weiterentwickelt werden.

Es seien $\mathbf{p}^{(1)}$ und $\mathbf{p}^{(2)}$ die normalverteilten Positionen der Fahrzeuge mit den Kovarianzmatrizen $\Sigma_p^{(1)}$ und $\Sigma_p^{(2)}$. Da multivariate Normalverteilungen faltungsstabil sind, ist die Differenz der Zufallsvariablen ebenfalls normalverteilt und es gilt:

$$\mathbf{p}^{(diff)} = \mathbf{p}^{(2)} - \mathbf{p}^{(1)} \quad (4.42)$$

$$\mathbf{p}^{(diff)} \sim \mathcal{N}(\mathbf{p}^{(diff)}; \mathbf{p}^{(2)} - \mathbf{p}^{(1)}, \Sigma_p^{(1)} + \Sigma_p^{(2)}) \quad (4.43)$$

4.10.1 Vernachlässigung von Orientierungsunsicherheiten

Unter Vernachlässigung von Orientierungsunsicherheiten kann der Kollisionsbereich der Differenzzufallsvariable direkt geometrisch bestimmt werden, Abb. 4.13. Eine Methode, den Kollisionsbereich A_K zu bestimmen, ist in Abb. 4.13b gezeigt. Dazu

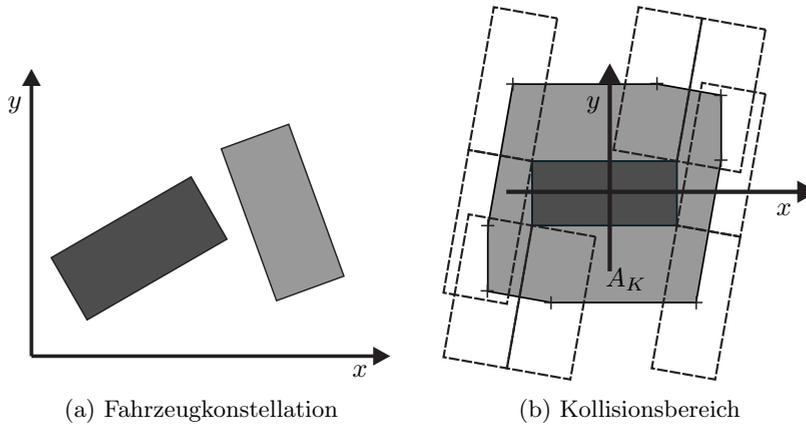


Abbildung 4.13: Links: Anordnung von zwei Fahrzeugen als potentielle Kollisionspartner. Rechts: Verschieben eines Fahrzeuges in den Ursprung durch Differenzbildung sowie Drehung zur achsparallelen Ausrichtung. Der Kollisionsbereich A_K wird durch Verschieben des zweiten Fahrzeugs an die Eckpunkte bestimmt (gestrichelt).

wird das erste Fahrzeug in den Koordinatenursprung verschoben und die Szene so gedreht, dass es achsparallel ausgerichtet ist. An die Eckpunkte der Objektbox wird nun die zweite Objektbox angelegt, so dass die Eckpunkte sich gerade berühren. Pro Eckpunkt der ersten Box gibt es unter den vier möglichen Konstellationen mindestens zwei, bei denen sich die Objekte nicht überlappen, in Abb. 4.13b gestrichelt dargestellt. Die Mittelpunkte des zweiten Objekts dieser Konstellationen beschreiben die i.Allg. achteckige Grenzfläche.⁷

Die gesuchte Kollisionswahrscheinlichkeit ist dann gerade die Wahrscheinlichkeit, dass der Differenzvektor im Kollisionsbereich A_K liegt.

$$P(\mathcal{C}) \approx \iint_{A_K} p^{(diff)} dx dy \quad (4.44)$$

⁷Im Grenzfall, dass die Objekte untereinander achsparallel ausgerichtet sind, gibt es drei solcher Konstellationen pro Ecke. Das Achteck degradiert zu einem Rechteck.

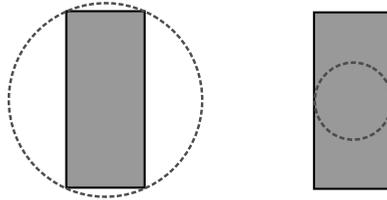


Abbildung 4.14: Näherung einer Objektbox über Außen- (links) und Innenkreis (rechts). Die Kreisnäherungen sind von der Orientierung der Objektbox unabhängig.

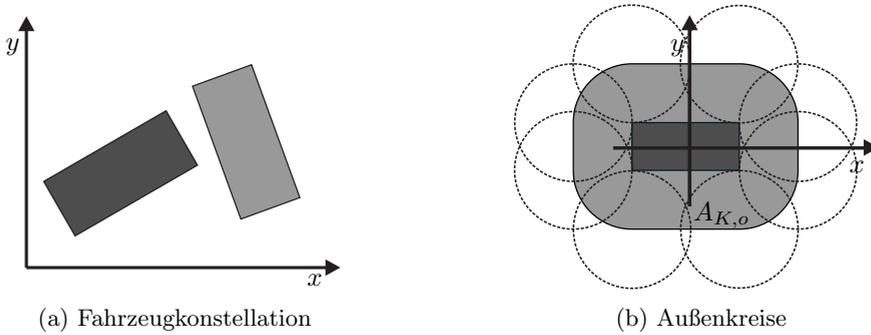
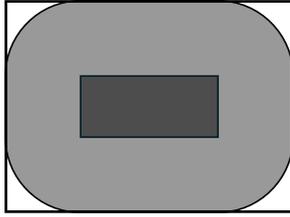


Abbildung 4.15: Bestimmung einer oberen Schranke für die Kollisionswahrscheinlichkeit über Außenkreise. Die Orientierungsunsicherheit des helleren Fahrzeugs soll berücksichtigt werden.

4.10.2 Berücksichtigung der Orientierungsunsicherheit eines Fahrzeugs

Falls eines der beiden Fahrzeuge eine nicht vernachlässigbare Orientierungsunsicherheit hat, ist es praktikabel, die Kollisionswahrscheinlichkeit zunächst über Betrachtungen von oberen und unteren Schranken einzugrenzen, und den Wert nur bei Bedarf genauer zu berechnen. Dazu wird diejenige Objektbox, für die die Orientierungsunsicherheit nicht vernachlässigbar ist, über Außen- und Innenkreise angenähert und dadurch unabhängig von der Orientierung gemacht, Abb. 4.14.



(a) Außenkreise



(b) Innenkreise

Abbildung 4.16: Annäherung der Rechtecke mit abgerundeten Ecken, die sich aus Außen- und Innenkreisabschätzungen ergeben. Außenkreisflächen werden durch ein Rechteck angenähert, wobei die Fläche überschätzt wird. Innenkreisflächen werden durch Achtecke angenähert bei Unterschätzung der Fläche. Die weißen Ecken kennzeichnen jeweils den überschätzten (links) bzw. unterschätzte (rechts) Fläche.

4.10.2.1 Berechnung einer oberen Schranke für die Kollisionswahrscheinlichkeit

Für die Analyse der oberen Schranke wird die Nummerierung in Gleichung (4.42) so gewählt, dass das Objekt mit vernachlässigbarer Orientierungsunsicherheit im Ursprung zum Liegen kommt. Für das andere Fahrzeug wird ein Außenkreis gebildet, dessen Ursprung in der Fahrzeugmitte ist und gerade so die Box umschließt, Abb. 4.15.

Zu einer Kollision kann es nur kommen, wenn sich der Differenzvektor im Außenkreisbereich $A_{K,o}$ befindet. Allerdings kommt es selbst in diesem Fall nicht immer zu einer Kollision. Die Integration der Wahrscheinlichkeitsdichte liefert eine obere Schranke der Kollisionswahrscheinlichkeit.

$$\overline{P(\mathcal{C})} = \iint_{A_{K,o}} p^{(diff)} dx dy \quad (4.45)$$

$$\overline{P(\mathcal{C})} \geq P(\mathcal{C}) \quad (4.46)$$

Die Fläche $A_{K,o}$ ergibt sich durch die Mittelpunkte eines auf dem Rechteck des ersten Fahrzeugs abgerollten Außenkreises, Abb. 4.15b. Es ergibt sich ein Rechteck mit abgerundeten Ecken. Für die einfachere numerische Behandlung wird die Fläche als Rechteck angenähert, Abb. 4.16a. Die obere Schranke ist dementsprechend etwas konservativer als nötig.

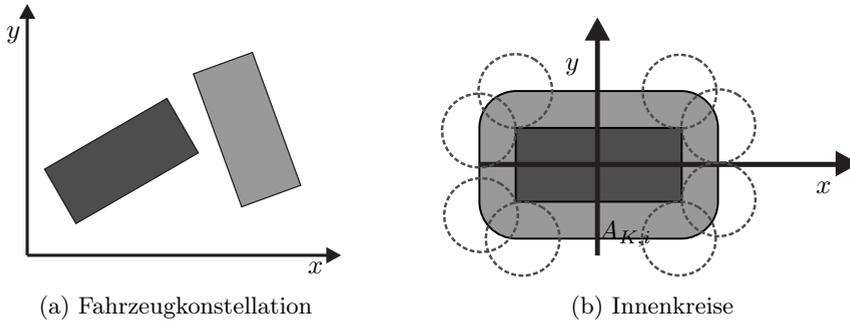


Abbildung 4.17: Bestimmung einer unteren Schranke für die Kollisionswahrscheinlichkeit über Innenkreise. Die Orientierungsunsicherheit des helleren Fahrzeugs soll berücksichtigt werden.

4.10.2.2 Berechnung einer unteren Schranke für die Kollisionswahrscheinlichkeit

Wird statt des Außenkreises der Innenkreis der Objektbox gewählt (Abb. 4.17), kommt es sicher zu einer Kollision bei einer entsprechenden Objektkonstellation, unabhängig von der Orientierung des Fahrzeugs mit hoher Orientierungsunsicherheit. Die Integration über den auf Basis des Innenkreises erstellten Bereich $A_{K,i}$ stellt somit eine untere Schranke für die Kollisionswahrscheinlichkeit dar.

$$\underline{P(\mathcal{C})} = \iint_{A_{K,i}} p^{(diff)} dx dy \tag{4.47}$$

$$\underline{P(\mathcal{C})} \leq P(\mathcal{C}) \tag{4.48}$$

Auch für die Fläche $A_{K,i}$ ergibt sich ein Rechteck mit abgerundeten Ecken, das entsprechend kleiner ausfällt, Abb. 4.17b.

Auch in diesem Fall soll die Fläche zur einfacheren numerischen Berechnung angenähert werden. Da das Ziel jetzt die Berechnung einer unteren Schranke ist, darf eine Annäherung die Fläche nicht vergrößern. Als einfache konservative Näherung wird ein Achteck gewählt, Abb. 4.16b.

Für das Gedankenexperiment, dass Außen- und Innenkreis übereinstimmen (also das zweite Fahrzeug kreisförmig ist), fallen obere und untere Schranke zusammen und die Kollisionswahrscheinlichkeit kann direkt angegeben werden.

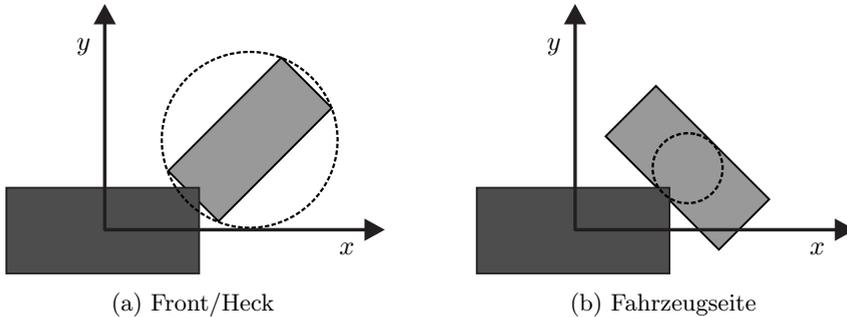


Abbildung 4.18: Wenn Fahrzeugfront oder -heck des zweiten Fahrzeugs in Richtung Koordinatenursprung zeigt, ist die Annäherung mit einem Außenkreis passend (links). Bei einer Ausrichtung der Fahrzeugseite in Richtung des Ursprungs ist die Innenkreisnäherung eher geeignet (rechts).

4.10.2.3 Annäherung der Kollisionswahrscheinlichkeit

Nach der Eingrenzung durch obere und untere Schranken soll die Kollisionswahrscheinlichkeit nun genauer bestimmt werden. Die grundlegende Idee ist, dass die wahre Kollisionswahrscheinlichkeit näher an der Näherung über den Außenkreis ist, wenn die Front- oder Heckpartie des Fahrzeugs in Richtung Ursprung (und damit des Kollisionspartners) zeigen, da Front und Heck vom Außenkreis besser angenähert werden, wie in Abb. 4.18a veranschaulicht wird. Wenn dagegen die Seiten der Objektbox in Richtung Ursprung gerichtet sind, ist eher die Näherung mit einem Innenkreis zutreffend, Abb. 4.18b.

Dazu wird die Ausrichtung des zweiten Fahrzeugs in die diskreten Winkelsektoren Front, Heck, Fahrerseite und Beifahrerseite eingeteilt, Abb. 4.19. Die Winkelbereiche für Front und Heck werden um $2\sigma_\psi$ aufgeweitet, um das Ausschlagen der Fahrzeugecken bei leichter Orientierungsänderung besser zu erfassen.

Mit der Verteilungsdichte der Orientierung f_ψ kann dann berechnet werden, mit welcher Wahrscheinlichkeit der jeweilige Winkelbereich zum Ursprung orientiert ist. Mit den Indizes F , H , S , B für Front, Heck, Fahrer- und Beifahrerseite ergibt sich beispielsweise für den Heckbereich

$$P_H = \int_{\psi \in \text{Hecksektor}} f_\psi d\psi. \quad (4.49)$$

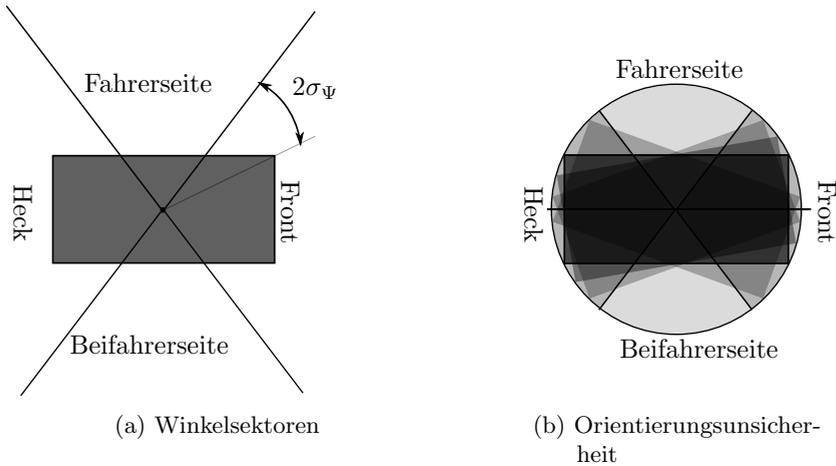


Abbildung 4.19: Winkelbereiche für die Sektoren Front, Heck, Fahrerseite und Beifahrerseite. Der Front- und Heckbereich wird um $\pm 2\sigma_\psi$ gegenüber der Fahrzeugecken aufgeweitet (links). Damit wird dem Umstand Rechnung getragen, dass bei Verdrehungen die Ecken des Fahrzeugs so ausschlagen, dass die Außenkreisnäherung passender ist (rechts).

Da die Winkelbereiche den gesamten Wertebereich des Gierwinkels abdecken, gilt

$$P_S + P_B + P_H + P_F = 1. \tag{4.50}$$

Abb. 4.20 zeigt ein schematisches Beispiel. Das Fahrzeug ist so orientiert, dass Beifahrerseite und Heck am ehesten in Richtung Ursprung zeigen. Die Wahrscheinlichkeiten P_F, P_B, P_H, P_S werden durch Integration der Wahrscheinlichkeitsdichtefunktion der Orientierung f_ψ über die gekennzeichneten Bereiche gewonnen.

Eine angenäherte Kollisionswahrscheinlichkeit ergibt sich aus der gewichteten Summe der oberen und unteren Schranke. Als Gewichte treten die Wahrscheinlichkeiten, dass die zugehörige Fahrzeugseite zum Ursprung zeigt, auf. Mit (4.50) ergibt sich

$$P(\mathcal{C}) \approx \underline{P(\mathcal{C})} \cdot (P_S + P_B) + \overline{P(\mathcal{C})} \cdot (P_H + P_F). \tag{4.51}$$

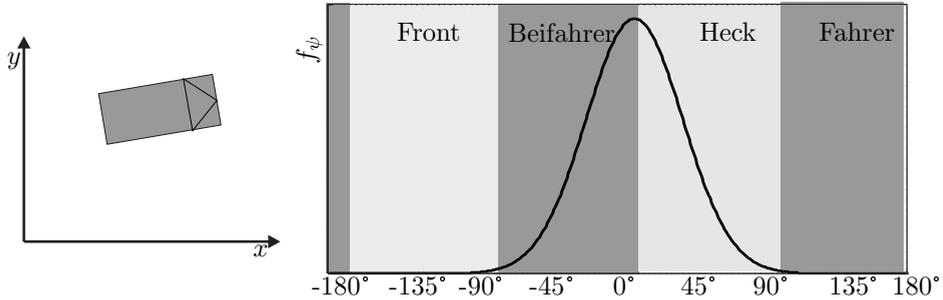


Abbildung 4.20: Wahrscheinlichkeitsdichte der Orientierung mit Einteilung der Sektoren. Links die Objektkonstellation, rechts die Einteilung in Sektoren und die Wahrscheinlichkeitsdichtefunktion der Orientierung.

4.10.3 Berücksichtigung der Orientierungsunsicherheit beider Fahrzeuge

Das beschriebene Vorgehen der Berücksichtigung der Orientierungsunsicherheit eines Fahrzeugs lässt sich auf den Fall ausweiten, dass diese für beide Fahrzeuge nicht vernachlässigbar ist.

Das Vorgehen erfolgt analog zu Abschnitt 4.10.2. Die Näherung durch Innen- und Außenkreise wird nun jedoch für beide Fahrzeuge vorgenommen.

4.10.3.1 Berechnung einer oberen Schranke für die Kollisionswahrscheinlichkeit über die Kombination von Außenkreis und Außenkreis

Zur Abschätzung der oberen Schranke werden beide Fahrzeuge mit ihrem Außenkreis angenähert. Der entstehende Kollisionsbereich ist nicht mehr wie in Abb. 4.15b ein Rechteck mit abgerundeten Ecken, sondern ein Kreis mit einem Radius R_A , der der Summe der Radien der beiden Außenkreise entspricht, Abb. 4.21b.

$$\overline{P(\mathcal{C})} = \iint_{x^2+y^2 \leq R_A^2} p^{(diff)} dx dy \quad (4.52)$$

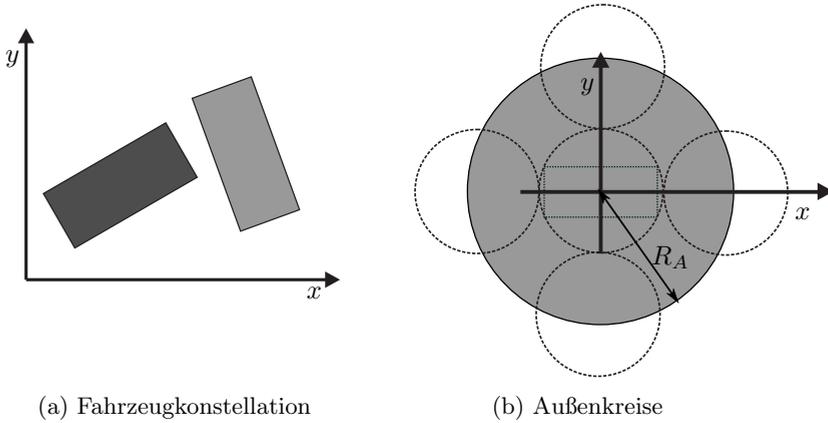


Abbildung 4.21: Bestimmung einer oberen Schranke für die Kollisionswahrscheinlichkeit über Außenkreise unter Berücksichtigung der Orientierungsunsicherheit für beide Fahrzeuge

4.10.3.2 Berechnung einer unteren Schranke für die Kollisionswahrscheinlichkeit über die Kombination von Innenkreis und Innenkreis

Die Annäherung beider Fahrzeuge mit dem Innenkreis ergibt eine untere Schranke für die Kollisionswahrscheinlichkeit. Auch in diesem Fall ist der Kollisionsbereich kreisförmig und es ergibt sich mit R_I als Summe der Innenkreisradien für die untere Schranke, Abb. 4.22b.

$$\underline{P(C)} = \iint_{x^2+y^2 \leq R_I^2} p^{(diff)} dx dy \quad (4.53)$$

4.10.3.3 Annäherung der Kollisionswahrscheinlichkeit

Die Annäherung der Kollisionswahrscheinlichkeit basierend auf der oberen und unteren Schranke wird ebenfalls analog zum Vorgehen aus dem letzten Abschnitt vorgenommen. Dieses Mal werden beide Fahrzeuge nach Abb. 4.19 in vier Winkelbereiche eingeteilt, die für Front, Heck, Fahrer- sowie Beifahrerseite stehen. Für die Ausrichtung der jeweils vier Winkelbereiche der beiden Fahrzeuge zueinander gibt es $4 \cdot 4 = 16$ Möglichkeiten. Allerdings ist es für die Kollisionswahrscheinlichkeit unwe-

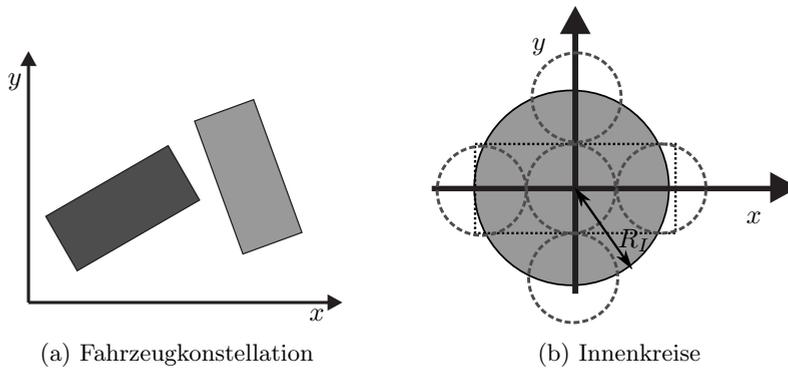


Abbildung 4.22: Bestimmung einer unteren Schranke für die Kollisionswahrscheinlichkeit über Innenkreise unter Berücksichtigung der Orientierungsunsicherheit für beide Fahrzeuge

sentlich, ob mit einer Fahrzeugfront oder einem Heck kollidiert wird. Unterscheidbar sind folgende vier Möglichkeiten:

Fall 1: Front/Heck von Fahrzeug 1 kollidiert mit Front/Heck von Fahrzeug 2

Fall 2: Front/Heck von Fahrzeug 1 kollidiert mit Fahrer-/Beifahrerseite von Fahrzeug 2

Fall 3: Fahrer-/Beifahrerseite von Fahrzeug 1 kollidiert mit Front/Heck von Fahrzeug 2

Fall 4: Fahrer-/Beifahrerseite von Fahrzeug 1 kollidiert mit Fahrer-/Beifahrerseite von Fahrzeug 2

Die Zustände der beiden Fahrzeuge werden weiterhin stochastisch unabhängig voneinander angenommen. Die individuellen Ausrichtungen können analog zu Gleichung (4.49) berechnet werden. Mit den Indizes 1 und 2 für das erste und zweite Fahrzeug, sowie F , H , S und B für Front, Heck, Fahrerseite und Beifahrerseite ergibt sich für die entsprechenden Wahrscheinlichkeiten der Objektausrichtungen für die

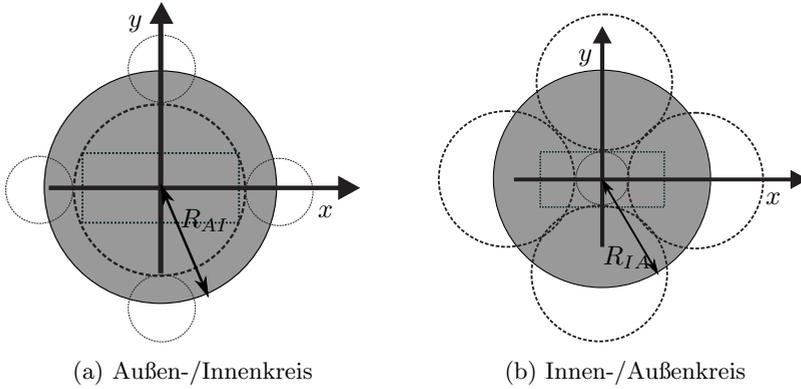


Abbildung 4.23: Kombinationen von Innen- und Außenkreisen zur Abschätzung der Kollisionen zwischen Font/Heck und Fahrer-/Beifahrerseite

Fälle 1–4:

$$P_1 = P_{1F} P_{2F} + P_{1F} P_{2H} + P_{1H} P_{2F} + P_{1H} P_{2H} \quad (4.54)$$

$$P_2 = P_{1F} P_{2S} + P_{1F} P_{2B} + P_{1H} P_{2S} + P_{1H} P_{2B} \quad (4.55)$$

$$P_3 = P_{1S} P_{2F} + P_{1S} P_{2H} + P_{1B} P_{2F} + P_{1B} P_{2H} \quad (4.56)$$

$$P_4 = P_{1S} P_{2S} + P_{1S} P_{2B} + P_{1B} P_{2S} + P_{1B} P_{2B} \quad (4.57)$$

Da die tatsächliche Ausrichtung durch eine dieser vier Fälle abgedeckt wird, gilt

$$P_1 + P_2 + P_3 + P_4 = 1. \quad (4.58)$$

Für Kombinationen von Front-/Heckkollisionen bzw. Seitenkollisionen wurden obere und untere Schranken über Außen- und Innenkreisabschätzungen angegeben. Für die Kombinationen, bei denen Front oder Heck mit Fahrer- oder Beifahrerseite kollidieren, können Abschätzungen basierend auf der Mischung von Innen- und Außenkreisabschätzungen erhalten werden, Abb. 4.23.

$$P_{m,2}(\mathcal{C}) = \iint_{x^2+y^2 \leq R_{AI}^2} p^{(diff)} dx dy \quad (4.59)$$

$$P_{m,3}(\mathcal{C}) = \iint_{x^2+y^2 \leq R_{IA}^2} p^{(diff)} dx dy \quad (4.60)$$

Die Kollisionswahrscheinlichkeit wird als gewichtete Summe der Kollisionswahrscheinlichkeiten mit den betreffenden Ausrichtungswahrscheinlichkeiten als Gewichten angenähert. Mit Gleichung (4.58) ergibt sich

$$P(\mathcal{C}) \approx \underline{P(\mathcal{C})} \cdot P_1 + P_{m,2}(\mathcal{C}) \cdot P_2 + P_{m,3}(\mathcal{C}) \cdot P_3 + \overline{P(\mathcal{C})} \cdot P_4. \quad (4.61)$$

4.10.4 Berücksichtigung von Orientierungsunsicherheiten durch Winkeldiskretisierung

Eine Alternative zur Annäherung mit Außen- und Innenkreisen ist die Diskretisierung von Winkelbereichen. Analog zur Berechnung des Faltungskerns bei der auf einem Grid basierenden Methode aus Abschnitt 4.6.3 wird der Orientierungswinkel in Segmente I_i unterteilt. Für jedes Segment wird die Wahrscheinlichkeit $P(\psi \in I_i)$ berechnet, dass der Orientierungswinkel in diesem Segment liegt. Anschließend wird der Winkel auf den Mittelwert des Segments gesetzt und für diesen Fall eine Kollisionsberechnung nach Abschnitt 4.10.1 vorgenommen.

$$P(\mathcal{C} | \psi \in I_i) = \iint_{A_K} p^{(diff)} dx dy \quad (4.62)$$

Die Kollisionswahrscheinlichkeit ergibt sich nach dem Gesetz der totalen Wahrscheinlichkeit zu

$$P(\mathcal{C}) = \sum_i P(\mathcal{C} | \psi \in I_i) \cdot P(\psi \in I_i) \quad (4.63)$$

Sollen Orientierungsunsicherheiten von beiden Fahrzeugen berücksichtigt werden, müssen beide Winkelbereiche diskretisiert werden und alle Kombinationen der Segmente berücksichtigt werden.

Insgesamt ist zu erwarten, dass der Aufwand bei der Berechnung im Vergleich zur Version ohne Berücksichtigung der Orientierungsunsicherheit linear bzw. quadratisch mit der Feinheit der Diskretisierung ansteigt, je nachdem, ob die Unsicherheit bei einem oder bei beiden Fahrzeugen berücksichtigt werden soll.

4.11 Auswertung der Methoden zur Bestimmung der Kollisionswahrscheinlichkeit

Um die vorgestellten Methoden hinsichtlich ihrer Aussagekraft beurteilen zu können, wird zunächst eine Grundwahrheit benötigt. Leider lässt sich diese selbst mit hohem Aufwand nicht exakt bestimmen, wie in den vorangehenden Abschnitten erklärt wurde. Deshalb wird auf Monte-Carlo-Sampling (Abschnitt 4.5) mit einer hohen Anzahl an Samples zurückgegriffen. Pro Fahrzeug wurden 500 Samples gezogen, was für eine hinreichend gute Wiederholgenauigkeit ausreicht (Abb. 4.4). Allerdings bedeutet das, dass Schwankungen in der folgenden Auswertung zu einem gewissen Teil auch durch die Referenzmethode bedingt sind.

Da Kollisionsszenarien mit realen Fahrzeugen nicht praktikabel sind, erfolgt die Auswertung simulativ. Dabei werden zufällig unterschiedliche Szenarien erzeugt. Ein Szenario besteht aus zwei als Boxen angenäherten Fahrzeugen mit jeweils zufälligen Abmessungen, Positionen und Ausrichtungen. Die Abmessungen werden als variabel, aber deterministisch angenommen. Für die Positionen und Ausrichtungen werden ebenfalls zufällig eine Kovarianzmatrix bzw. eine Varianz erzeugt.

Die Positionen werden dabei zunächst auf ein Gebiet von $10\text{ m} \times 10\text{ m}$ eingegrenzt. Anschließend wird dieses Gebiet immer weiter verkleinert, um auch für höhere Kollisionswahrscheinlichkeiten eine hinreichende Anzahl an Szenarien zu erhalten.

Wie erwähnt wurden neben dem dynamischen Zustand auch die Abmessungen der Fahrzeuge variiert. Dabei wurden Längen zwischen 4 m und 5 m und Breiten zwischen $1,70\text{ m}$ und $2,30\text{ m}$ zugelassen.

Für jedes Szenario wurde die Referenz-Kollisionswahrscheinlichkeit mit Monte-Carlo-Sampling sowie mit der jeweiligen Methode berechnet. Die Ergebnisse der Näherungsmethode werden in einem Streudiagramm über den Werten der Referenzmethode aufgetragen.

Für Methoden, die ein Maß für die Kollisionswahrscheinlichkeit liefern, sollte sich eine streng monotone Kurve ergeben, so dass die Kollisionswahrscheinlichkeit mit einer Kalibrierkurve nach Abb. 4.11 angegeben werden kann.

Methoden, die direkt Kollisionswahrscheinlichkeiten berechnen, sollten im Idealfall die erste Winkelhalbierende im Streudiagramm ergeben. Allerdings wird auch in diesem Fall über Regression eine Kalibrierkurve berechnet, über die beispielsweise systematische Fehler gemindert werden können.

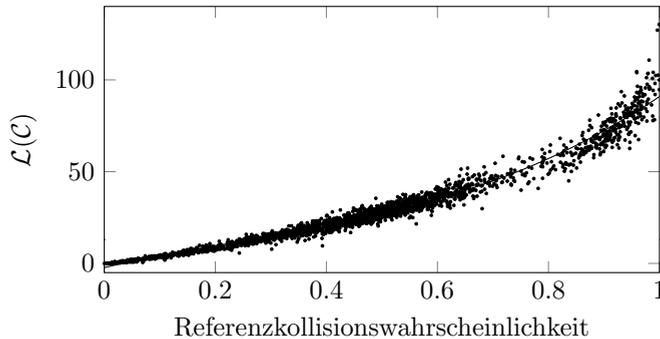


Abbildung 4.24: Ergebnisse der Methode der Summe der Kollisionswahrscheinlichkeiten in den einzelnen Zellen. Das Ergebnis ist selbst keine Wahrscheinlichkeit, aber streng monoton bezüglich der Referenzmethode.

Im Anschluss werden alle Methoden hinsichtlich Rechenaufwand und Streuung der Ergebnisse tabellarisch gegenübergestellt.

4.11.1 Auswertung des Grid-Ansatzes zur Bestimmung von Kollisionswahrscheinlichkeiten über Faltungsoperatoren

In diesem Abschnitt werden die Ergebnisse des Grid-Ansatzes über Faltungsoperatoren (Abschnitt 4.6) untersucht.

4.11.1.1 Summe der Kollisionswahrscheinlichkeiten in den einzelnen Zellen

Die erste Methode, ein Maß für die Kollisionswahrscheinlichkeit anzugeben, war die Bildung der Summe der Kollisionswahrscheinlichkeiten in den einzelnen Zellen nach Gleichung (4.20) zur Berechnung des Zählwertes $\mathcal{L}(\mathcal{C})$. Abb. 4.24 zeigt das zugehörige Streudiagramm. Die Erwartung, dass der Wert von $\mathcal{L}(\mathcal{C})$ größer als eins werden kann, findet sich bestätigt. Es ist jedoch möglich, über Regression eine streng monotone Kallibrierkurve zu finden, so dass der Wert als Maß nutzbar ist.

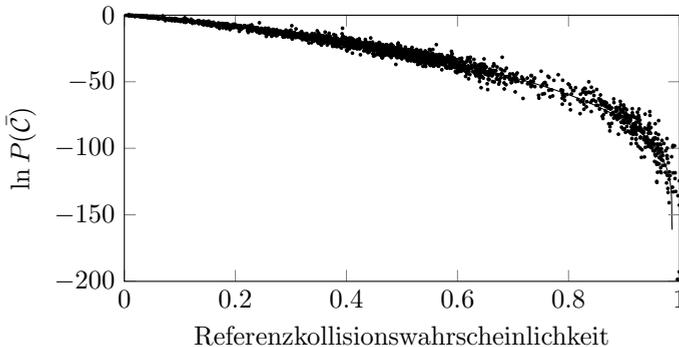


Abbildung 4.25: Ergebnisse der Methode des Komplementärereignisses, dass in keiner der Zellen eine Kollision stattfand. Die Rechnung erfolgt aus numerischen Gründen im logarithmischen Bereich.

4.11.1.2 Komplementärereignis

Eine alternative Berechnungsmethode über das Komplementärereignis wurde in Gleichungen (4.21) und (4.22) dargestellt. Allerdings ergeben sich bei der Auswertung dieser Gleichungen durch lange Ketten aus Produkten kleiner Zahlen sehr kleine Werte. Es muss damit gerechnet werden, dass das Verfahren ohne Modifikationen numerisch instabil wird und in dieser Form nicht nutzbar ist. Aus diesem Grund wurde die Berechnung analog zu Abschnitt 3.4.1 im logarithmischen Bereich ausgeführt.

Abb. 4.25 zeigt die Ergebnisse der logarithmierten komplementären Kollisionswahrscheinlichkeit $\ln P(\bar{C})$. Auch hier ist ein streng monotoner Verlauf annäherbar, damit liegt eine prinzipielle Eignung der Methode zur Kollisionsabschätzung vor.

4.11.2 Auswertung des Grid-Ansatzes zur Bestimmung von Kollisionswahrscheinlichkeiten über Zustandsdiskretisierung

Da diese Methode der Auswertung des Ansatzes über Zustandsdiskretisierung im Grid (Abschnitt 4.7, insbesondere Gleichung (4.26)) sehr aufwändig ist, wurden nur wenige Szenarien untersucht. Um den Einfluss von Streuungen der Referenzmethode trotz der gesunkenen Anzahl an Szenarien gering zu halten, wurden jeweils zehn Durchgänge der Referenzmethode gerechnet und die Ergebnisse gemittelt.

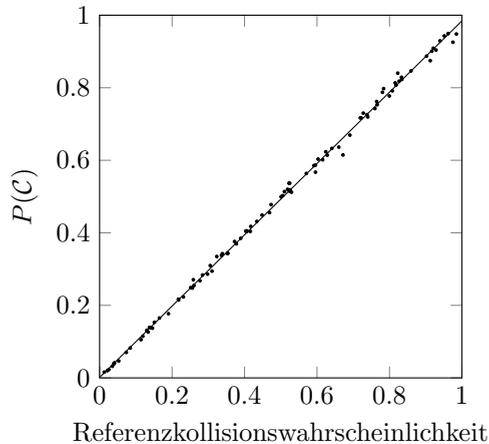


Abbildung 4.26: Ergebnisse der Methode der Berechnung der Kollisionswahrscheinlichkeit über Zustandsdiskretisierung. Über diese Methode können echte Wahrscheinlichkeitswerte erhalten werden, die zudem noch sehr exakt sind.

Die Ergebnisse sind in Abb. 4.26 dargestellt. Es ergibt sich für alle Szenarien nur eine geringe Streuung um die erste Winkelhalbierende. Diese Methode liefert vergleichbar genaue Ergebnisse wie die Referenzmethode, allerdings zum Preis eines hohen Rechenaufwandes, wie in Abschnitt 4.11.3 gezeigt wird.

4.11.3 Auswertung der Annäherung der Kollisionswahrscheinlichkeit über das Produkt der Wahrscheinlichkeitsdichten

In den vorhergehenden Abschnitten wurden als Alternative zu Grid-Ansätzen einfachere Näherungsverfahren beschrieben. In Abschnitt 4.9 wurde in Gleichung (4.41) aufgezeigt, wie die Fläche unter der Kurve des Produktes der Wahrscheinlichkeitsdichteverteilungen von zwei Fahrzeugpositionen analytisch geschlossen berechnet werden kann. Die Ergebnisse dieser Methode finden sich in Abb. 4.27.

Wie aus der Abbildung ersichtlich, besteht ein monotoner Zusammenhang zwischen dem Produkt und der Kollisionswahrscheinlichkeit. Es gibt einige wenige Ausreißer, die allerdings die Nutzbarkeit dieses Ansatzes grundlegend in Frage stellen. Ein Extremfall, bei dem die Referenzkollisionswahrscheinlichkeit bei ca. 75% liegt, die Fläche A sich jedoch beinahe zu null ergibt, ist in Abb. 4.27b enthalten.

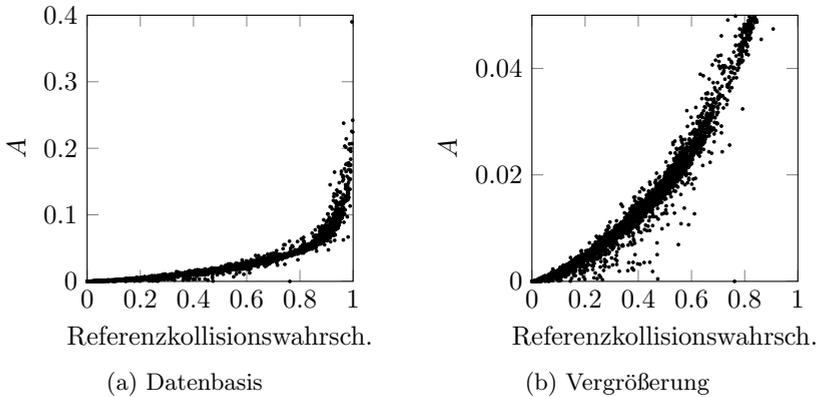


Abbildung 4.27: Produkt der Wahrscheinlichkeitsdichtefunktionen als Maß für die Kollisionswahrscheinlichkeit. Links: Vollständige Datenbasis. Rechts: Vergrößerung des Bereichs unterhalb ca. 80%.

Der Grund für diese Fehleinschätzung ist leicht verständlich. Wenn die Positionen von zwei Fahrzeugen vergleichsweise sicher bekannt sind, fallen die Wahrscheinlichkeitsdichtefunktionen schnell ab. Damit ist ihre Überlappung gering, selbst wenn die Erwartungswerte nah beieinander liegen. Dadurch kann mit recht großer Wahrscheinlichkeit eine Kollision vorliegen, die von dem Ansatz, der Objektdimensionen nicht berücksichtigt, übersehen wird. Dieses Szenario ist schematisch eindimensional in Abb. 4.28 dargestellt.

Andererseits werden für einen Großteil der Szenarien mit kleinem Aufwand passende Kollisionswahrscheinlichkeiten zugewiesen, wie im direkten Vergleich der Verfahren in Abschnitt 4.12 gezeigt wird. Es wäre wünschenswert, das Verfahren zumindest für eine Vorauswahl nutzen zu können, um aus der Menge an potentiellen Gefahrenstellen nur diejenigen Szenarien rauszusuchen, für die sich aufwändigere Verfahren lohnen. Dazu ist eine Einschränkung des Vorgehens erforderlich.

Die Fläche A beschreibt den Überlappungsgrad der Dichtefunktionen. Der Überlappungsgrad ist jedoch nur dann ein aussagekräftiges Maß für eine Kollisionswahrscheinlichkeit, wenn diese durch die Positionsunsicherheit dominiert wird. Üben andererseits die Objektdimensionen entscheidenden Einfluss aus, verliert die Fläche A als Maß an Aussagekraft.

In der Schlussfolgerung sollte die Methode nur angewendet werden, wenn die Unsicherheit dominant gegenüber den Objektausmaßen ist. Dies kann über das Verhältnis

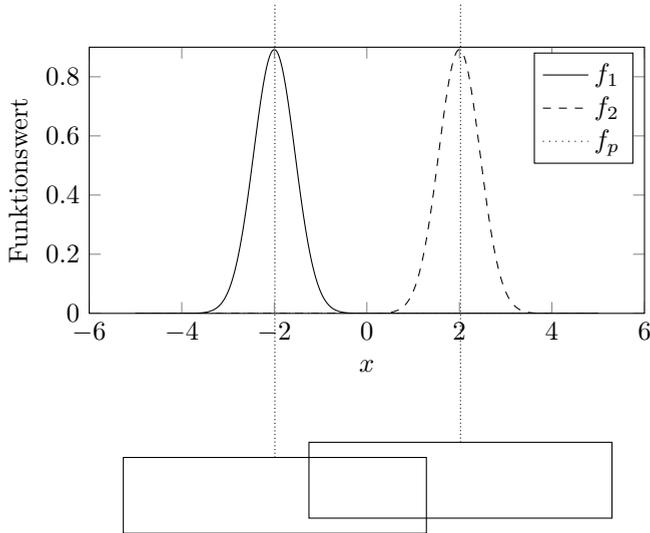


Abbildung 4.28: Das Produkt zweier nah beieinander liegender Wahrscheinlichkeitsdichtefunktionen mit jeweils kleiner Varianz verschwindet, der Verlauf von f_p im Überlappungsbereich bei 0 ist nicht mehr sichtbar, die Fläche unter der Kurve ist dementsprechend nahe null. Entsprechende Objektboxen würden sich jedoch mit hoher Wahrscheinlichkeit überlappen.

von maximaler Objektdimension und minimaler Standardabweichung modelliert werden.

Sei σ_{min} die kleinste Standardabweichung, die aus den vier Eigenwerten der Kovarianzmatrizen Σ_1 und Σ_2 berechnet wurde, und d_{max} die maximale Objektdimension der beiden Fahrzeuge. Das dimensionslose Verhältnis r

$$r = \frac{\sigma_{min}}{d_{max}} \geq r_{thres} \quad (4.64)$$

setzt Unsicherheit und Objektausmaße in Relation. Über eine Schwellwertbildung mit r_{thres} auf diesem Verhältnis können Szenarien von der Behandlung mit der vorliegenden Methode ausgeschlossen werden. Ein Schwellwert von null bewirkt eine Berücksichtigung aller Szenarien. Steigende Werte des Schwellwertes verlangen eine immer größere Unsicherheit im Verhältnis zu den Objektdimensionen und sortieren damit immer mehr Szenarien aus.

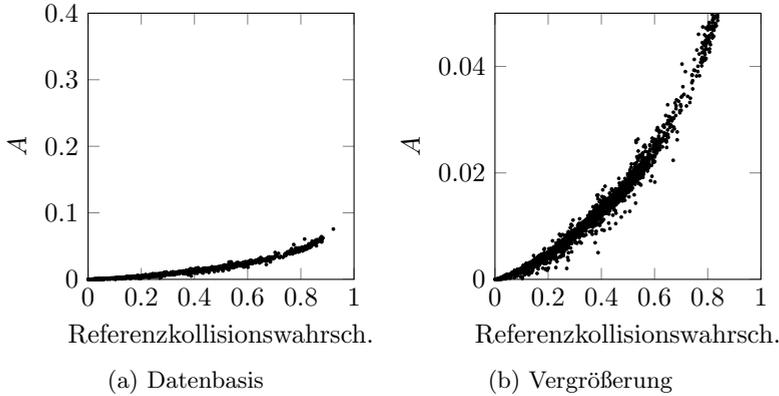


Abbildung 4.29: Produkt der Wahrscheinlichkeitsdichtefunktionen als Maß für die Kollisionswahrscheinlichkeit. Es wurden nur Szenarien berücksichtigt, deren Unsicherheits- / Dimensionsverhältnis r über dem Schwellwert $r_{thres} = 0,2$ liegt.

Abb. 4.29 zeigt das Ergebnis für einen Schwellwert von $r_{thres} = 0,2$. Im Vergleich zur vollständigen Datenbasis aus Abb. 4.27 fällt auf, dass die Szenarien, die zu einer extremen Unterschätzung der Kollisionswahrscheinlichkeit geführt haben, ausgefiltert wurden. Insgesamt hat die Anzahl der sichtbaren Abweichungen stark abgenommen. Das Ergebnis ähnelt der Situation der in vorigen Abschnitten besprochenen aufwändigeren Methoden.

Ebenfalls auffällig ist, dass Szenarien mit hohen Kollisionswahrscheinlichkeiten zum großen Teil durch die Schwellwertbildung herausgefallen sind. Dieser Umstand liegt darin begründet, dass Szenarien mit signifikanten Unsicherheiten prinzipiell keine sicheren Kollisionsszenarien sind.

4.11.4 Auswertung der Annäherung der Kollisionswahrscheinlichkeit über die Differenz der Positionen

Als weitere Alternative wurde die Annäherung der Kollisionswahrscheinlichkeit über die Differenz der Positionen vorgestellt. Je nach Behandlung von Orientierungsunsicherheiten wurden unterschiedliche Ansätze aufgezeigt.

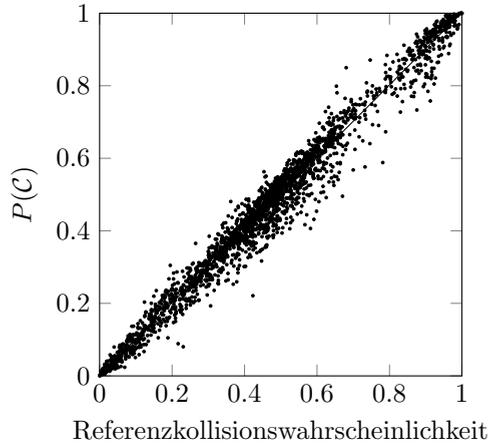


Abbildung 4.30: Kollisionswahrscheinlichkeit über Differenz der Positionen ohne Berücksichtigung von Orientierungsunsicherheiten

4.11.4.1 Vernachlässigung von Orientierungsunsicherheiten

Unter Vernachlässigung der Orientierungsunsicherheiten von beiden Fahrzeugen konnte ein rechentechnisch einfacher Ansatz in Abschnitt 4.10.1 vorgestellt werden. Abb. 4.30 zeigt die Ergebnisse. Das Verfahren liefert Werte für die Kollisionswahrscheinlichkeit, die zwar um die erste Winkelhalbierende herum liegen, allerdings einer recht großen Streuung unterworfen sind. Da diese Methode auf der anderen Seite mit günstigem Ressourcenbedarf umsetzbar ist, kann sie genutzt werden, um schnell eine grobe Schätzung zu erhalten, die im Weiteren nur bei Bedarf detaillierter ausgewertet wird.

Zu beachten ist, dass die Simulationen Szenarien mit großen Unsicherheiten in der Ausrichtung beinhalten. Die schlauchförmige Anordnung der Ergebnisse um die erste Winkelhalbierende herum deutet darauf hin, dass die Orientierung der Fahrzeuge einen Einfluss von ca. 20 Prozentpunkten zum Kollisionsergebnis beisteuert. Die hauptsächliche Einflussgröße ist jedoch die räumliche Anordnung der Fahrzeugpositionen.

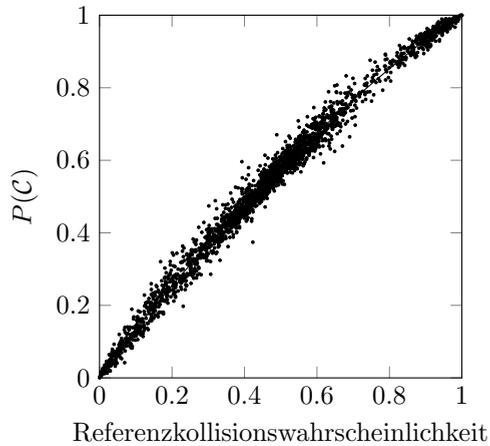


Abbildung 4.31: Kollisionswahrscheinlichkeit über Differenz der Positionen mit Berücksichtigung der größeren Orientierungsunsicherheit

4.11.4.2 Berücksichtigung der Orientierungsunsicherheit eines Fahrzeugs

Vernachlässigt man nur die kleinere Orientierungsunsicherheit der beiden Fahrzeuge und nähert die größere Unsicherheit mit dem in Abschnitt 4.10.2 beschriebenen Verfahren über Außen- und Innenkreisabschätzungen nach Gleichung (4.51) an, erhält man das Ergebnis aus Abb. 4.31.

Es zeigt sich eine Verringerung der Streuung gegenüber einer völligen Vernachlässigung der Orientierungsunsicherheiten aus Abb. 4.30. Quantifiziert wird der Unterschied im Vergleich aller untersuchten Methoden in Tabelle 4.1.

4.11.4.3 Berücksichtigung der Orientierungsunsicherheit beider Fahrzeuge

Werden beide Orientierungsunsicherheiten nach Gleichung (4.61) aus Abschnitt 4.10.3 in die Rechnung einbezogen, ergibt sich das Ergebnis aus Abb. 4.32.

Die Resultate sind insgesamt näher an der Winkelhalbierenden, sowohl die Streuung als auch die absoluten Fehler nach Kompensation mit der Regressionskurve sind

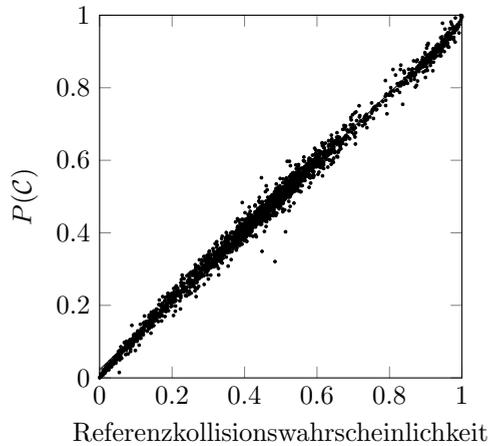


Abbildung 4.32: Kollisionswahrscheinlichkeit über Differenz der Positionen mit Berücksichtigung der Orientierungsunsicherheiten beider Fahrzeuge

allerdings vergleichbar mit der Betrachtung nur einer Orientierungsunsicherheit aus dem vorangegangenen Abschnitt.

4.11.4.4 Berücksichtigung der Orientierungsunsicherheit durch Winkeldiskretisierung

Alternativ zum Vorgehen, die Orientierungsunsicherheit durch Außen- und Innenkreise anzunähern, wurde in Abschnitt 4.10.4, Gleichung (4.63), ein Ansatz vorgestellt, der dasselbe Ziel über Winkeldiskretisierungen von einem oder beiden Fahrzeugen erreicht.

Abb. 4.33 zeigt die Auswertung der Ergebnisse. Auffällig ist die sehr gute Annäherung der ersten Winkelhalbierenden in der Regression mit vergleichsweise geringer Streuung. Allerdings muss dafür mit einem hohen Rechenaufwand bezahlt werden.

Bei der Diskretisierung der Winkelbereiche von beiden Fahrzeugen in Abb. 4.33b wurde aus diesem Grund der Umfang der Auswertung stark reduziert. Auch im Rahmen dieser Reduktion wurden jeweils zehn Durchgänge der Referenzmethode gerechnet und die Ergebnisse gemittelt, um den Einfluss von Streuungen der Referenz bei dem geringen Datenvolumen gering zu halten. Im Ergebnis ist deutlich erkennbar, dass diese Methode sehr genaue Ergebnisse liefert.

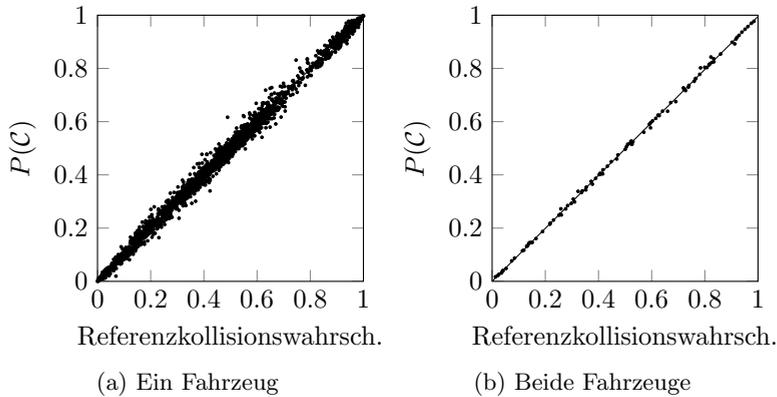


Abbildung 4.33: Kollisionswahrscheinlichkeit über Differenz der Positionen mit Berücksichtigung der Orientierungsunsicherheiten eines (links) oder beider (rechts) Fahrzeuge durch Winkel-diskretisierung. Es ergibt sich eine gute Näherung der Kollisionswahrscheinlichkeit, allerdings bei hohem Rechenaufwand.

4.12 Vergleich hinsichtlich Laufzeit und Streuung

Die beschriebenen Ansätze werden in Tabelle 4.1 hinsichtlich Laufzeit und Streuung der Werte gegenübergestellt.

Die Methoden zur Auswertung der Kollisionswahrscheinlichkeit wurden in Matlab implementiert. Die Angaben zur Laufzeit sind relativ zur Referenzmethode, einer Monte-Carlo-Auswertung mit 500 Samples, zu verstehen.

Mehrere Methoden erzeugen nicht direkt eine Kollisionswahrscheinlichkeit, sondern ein sich dazu monoton verhaltendes Maß. Dementsprechend wird keine absolute Genauigkeit, sondern ein Fehlerbetrag ausgewertet. Dazu wird für jede Methode eine Regressionskurve durch die Ergebnisdaten gelegt. Bei der Auswertung wird der Wert des Maßes berechnet und die zugehörige Kollisionswahrscheinlichkeit über die Regressionskurve ermittelt.

Für jedes Szenario ergibt sich damit eine geschätzte Kollisionswahrscheinlichkeit, die mit der Referenzmethode verglichen wird, um einen Fehler zu erhalten. In Tabelle 4.1 aufgetragen sind die 95. Perzentile der Fehlerbeträge. Das bedeutet,

Tabelle 4.1: Vergleich der vorgestellten Methoden zur Kollisionswahrscheinlichkeitsabschätzung hinsichtlich Rechenzeit und Fehlerperzentil

Methode	Rechenzeit bezogen auf die Referenzmethode	95. Perzentil des Fehlerbetrages
Monte-Carlo-Sampling (500 Samples, Referenz)	100%	0,020
Grid-Ansätze		
über Faltungsoperatoren		
Summe der Einzelzellen	65%	0,060
Komplementärereignis	65%	0,059
über Zustandsdiskretisierung	2178%	0,022
Differenz der Positionen		
über Außen-/Innenkreis		
ohne Orientierungsunsich.	2%	0,081
eine Orientierungsunsich.	3%	0,047
beide Orientierungsunsich.	7%	0,037
mittels Winkeldiskretisierung		
eine Orientierungsunsich.	36%	0,038
beide Orientierungsunsich.	678%	0,016
Produkt der Dichten		
mit $r_{thres} = 0$	≪≪ 1%	0,056
mit $r_{thres} = 0,2$	≪≪ 1%	0,045

dass 95% aller Szenarien in einem Intervall des jeweiligen Perzentil-Wertes um den Referenzwert herum liegen. Das 95. Perzentil der Referenzmethode selbst wurde durch eine hundertfache Wiederholung der Methode ermittelt.

4.13 Diskussion

Keine der vorgestellten Methoden zur Auswertung einer Kollisionswahrscheinlichkeit kann klar favorisiert werden. Verschiedene Methoden haben ihre spezifischen Stärken und Schwächen, die je nach Gewichtung den einen oder den anderen Ansatz vorteilhaft erscheinen lassen. Die Wahl der Methode hängt stark vom Einsatzzweck und den Rahmenbedingungen ab.

Hohe Genauigkeiten lassen sich durch Monte-Carlo-Sampling erreichen. Darüber hinaus trifft dieser Ansatz sehr wenige Annahmen über das Szenario. Insbesondere werden keine spezifischen Wahrscheinlichkeitsverteilungen vorausgesetzt. Dieser Umstand macht Monte-Carlo-Verfahren sehr flexibel und universal einsetzbar.

Allerdings haben Monte-Carlo-Verfahren auch hohe Anforderungen an Rechenressourcen. Zwar sind die Verfahren gut parallelisierbar, da jedoch typischerweise mehrere Szenarien unabhängig voneinander untersucht werden müssen (da über mehrere diskrete Zeitschritte prädictiert wird, und sich unter Umständen mehrere potentielle Kollisionspartner im Umfeld befinden), gilt dies in gewissem Umfang für alle Methoden und stellt kein Alleinstellungsmerkmal von Monte-Carlo-Ansätzen dar. Insgesamt eignet sich dieses Verfahren mit aktuellen Rechenarchitekturen nicht für die beständige echtzeitfähige Untersuchung von vielen Szenarien.

Mit Grid-Ansätzen können ebenfalls gute Ergebnisse erzielt werden. In um ca. ein Drittel kürzerer Zeit konnten Ergebnisse erzielt werden, deren Fehler in 95% der Fälle unter 5% lagen. Grid-Ansätze haben zudem das Potential, hochoptimiert implementiert zu werden. Durch Interpretation der Belegungsraaster als Bilder kann auf optimierte Rechenarchitekturen zurückgegriffen werden [HKOB10]. Zudem bieten auch Grid-Ansätze den Vorteil, für beliebige Wahrscheinlichkeitsverteilungen nutzbar zu sein. So können auch nichtparametrische Methoden der Wahrscheinlichkeitsmodellierung, die beispielsweise aus einer belegungskartenbasierten Prädiktion resultieren, ausgewertet werden.

Für den in Prädiktion und Modellierung häufig genutzten Spezialfall der normalverteilten Zufallsvariablen bietet die Methode der Differenz der Positionen eine sehr effiziente Möglichkeit, mit geringem Aufwand zu einer guten Abschätzung der Kollisionswahrscheinlichkeit zu kommen. Die Fehlermaße liegen im Bereich der

Grid-Ansätze, wobei je nach Berücksichtigung der Orientierungsunsicherheiten eine zusätzliche Wahlmöglichkeit zwischen Genauigkeit und Aufwand besteht.

Eine äußerst recheneffiziente Abschätzung der Kollisionswahrscheinlichkeit für normalverteilte Zufallsvariablen ist über das Produkt der Wahrscheinlichkeitsdichtefunktionen möglich. Die Streuung des Fehlers ist bei diesen Methoden überraschend gering. Voraussetzung für diesen Ansatz ist dennoch eine gewisse Dominanz der Positionsunsicherheit gegenüber der Objektdimensionen, um grobe Fehleinschätzungen in seltenen Objektkonstellationen zu vermeiden. Der Rechenaufwand dieser Methode ist gegenüber den aufgezeigten Alternativen praktisch vernachlässigbar.

Eine weiterer möglicher Lösungsansatz besteht in der Diskretisierung des vollständigen Zustandsraums oder zumindest im Orientierungswinkel eines oder beider Fahrzeuge. Während auf diese Weise ebenfalls gute Ergebnisse erreichbar sind, steigt der zu treibende Aufwand derart an, dass keine Vorteile gegenüber Monte-Carlo-Verfahren erkennbar waren.

Insgesamt betrachtet empfiehlt sich bei der Auswertung einer Fahrsituation, aus der typischerweise großen Anzahl der möglichen Kollisionsszenarien über das Produkt der Wahrscheinlichkeitsdichten die relevanten Konstellationen herauszufinden. Szenarien, die die Voraussetzungen der Anwendung dieser Methode nicht erfüllen oder die sich als besonders kollisionsrelevant herausgestellt haben, sollten im Nachgang mit einer genaueren Methode untersucht werden. Falls von normalverteilten Zufallsvariablen ausgegangen werden kann, bieten sich hierfür die Verfahren über die Differenz der Positionen an. Im anderen Fall bietet es sich an, auf einen Grid-Ansatz zurückzugreifen. Ob Unsicherheiten in der Orientierung berücksichtigt werden sollen oder nicht, kann dabei z. B. von der Größe der Unsicherheit oder aber der Fahrsituation abhängig gemacht werden. Beispielsweise bietet es sich im Kreuzungsumfeld an, die Unsicherheiten in der Orientierung zu betrachten, während diese bei Autobahnsszenarien als weniger relevant eingeschätzt werden können.

Für alle beschriebenen Verfahren gilt, dass sich der betrachtete Fehler auf die Auswertung der Kollisionswahrscheinlichkeit für eine gegebene unsicherheitsbehaftete Objektkonstellation bezieht. Die Objektkonstellation selbst ergibt sich typischerweise aus einer Prädiktion. Wie gezeigt wurde, haben neben den Objektpositionen auch die Orientierungen eine große Auswirkung auf die Kollisionswahrscheinlichkeit. Gut geschätzte Unsicherheiten können ferner dabei helfen, passende Methoden bei der Kollisionsbewertung auszuwählen, um den Rechenaufwand zu minimieren.

Um diesen Ansprüchen zu genügen und gute Schätzungen von Zuständen und Unsicherheiten abzugeben, können Prädiktionsverfahren von Kontextinformationen zu einer Fahrsituation profitieren. Wie im Systemüberblick in Abschnitt 2.2 beschrieben, kann die Absichtserkennung einen wichtigen Beitrag zu diesem Kontext liefern.

Kapitel 5

Zusammenfassung

Assistenzsysteme, die den Fahrer rechtzeitig vor gefährlichen Situationen warnen, müssen die menschliche Reaktionszeit mit einbeziehen. Hier ergibt sich die Schwierigkeit, dass rein unter Berücksichtigung der Fahrphysik sowie von Totzeiten der letztmögliche Warnzeitpunkt auch während normaler, als unkritisch empfundener Fahrt beständig durchbrochen wird. Ein warnendes System, das sich nur auf diese Informationen stützt, würde dementsprechend entweder häufig Falschalarme produzieren oder es wäre nutzlos. Dieser Umstand wird als Warndilemma bezeichnet.

In der vorliegenden Arbeit wurden ausgehend von einer messtechnischen Untersuchung des Warndilemmas Konsequenzen für Assistenzsysteme am Beispiel eines Kreuzungsassistenten betrachtet. Diese Untersuchungen resultierten in der Erkenntnis, dass für warnende Systeme, die einen Prädiktionshorizont von mehreren Sekunden benötigen, zusätzliche Kontextinformationen unabdinglich sind. Als wichtige Einflussgröße auf die Entwicklung einer Verkehrssituation wird die Absicht eines Fahrers, ein diskretes Manöver (wie z. B. einen Fahrstreifenwechsel oder einen Abbiegevorgang) einzuleiten, identifiziert.

Statistiken zeigen zudem, dass Unfälle zu einem erheblichen Teil durch menschliches Fehlverhalten verursacht werden. Dieses Fehlverhalten besteht zumeist darin, ein Manöver zu beginnen, das der Situation nicht angepasst ist oder der Umgebung nicht ordnungsgemäß angezeigt wurde bzw. ein Manöver zu unterlassen, das eine Gefahr abwenden würde.

In der vorliegenden Arbeit wurden Hidden-Markov-Modelle erfolgreich angewendet, um eine frühzeitige Erkennung der Absicht von Autofahrern, ein Fahrmanöver zu beginnen, umzusetzen. Als Merkmale wurde auf Signale vom Fahrzeug-Bus, digitale Karten und eine kamerabasierte Fahrstreifenenerkennung zurückgegriffen.

Durch die Beschränkung auf lineare Markov-Modelle war es möglich, Markov-Ketten

für vollständige Manöver zu trainieren, aus denen bedeutungstragende Untermodelle extrahiert werden konnten. Die extrahierten Modelle wurden dabei so gewählt, dass sie auf einen Signalverlauf bei Manöverbeginn passen, um eine möglichst frühzeitige Erkennung zu gewährleisten.

Es wurde gezeigt, dass eine Manövererkennung basierend auf diesen extrahierten Modellen rein anhand von Produktionswahrscheinlichkeiten erfolgen kann, was eine recheneffiziente Klassifikation ermöglicht. Ein Dekodierungsschritt ist nicht notwendig.

Die lineare Struktur der Hidden-Markov-Modelle ermöglicht auch die Betrachtung des typischen Pfades einer Beobachtungsfolge durch die Markov-Kette. Dies kann nicht nur die Berechnung weiter beschleunigen, sondern auch Verfälschungen entgegenwirken, die von unterschiedlichen Varianzen in der Emissionsmodellierung im Zusammenhang mit der in Markov-Modellen angenommenen geometrischen Verteilung der Zustandsübergänge verursacht werden.

Die Klassifikatorleistung wurde mit einem umfangreichen, manuell markierten Referenzdatensatz bestehend aus Fahrten in realem Straßenverkehr anhand verschiedener Kriterien evaluiert. Dabei zeigte sich eine sehr gute Erkennungsleistung der eingesetzten Klassifikatoren. Für den knapp 10 h umfassenden Referenzdatensatz konnte nachgewiesen werden, dass Klassifikationsfehler in fast allen Fällen auf Schwächen bei der Berechnung der Merkmale zurückzuführen waren. Zukünftiges Verbesserungspotential wird vor allem in der Verbesserung der Erzeugung der Merkmale gesehen. Mit der probabilistischen Kenntnis der Manöverwahrscheinlichkeiten kann eine Trajektorienprädiktion vorgenommen werden.

Abschliessend wurde die Gefährlichkeit von Konstellationen unsicherheitsbehafteter prädizierter Trajektorien anhand von Metriken für Kollisionswahrscheinlichkeiten abgeschätzt. Dafür wurden Approximationen für Kollisionswahrscheinlichkeiten entwickelt und gegenübergestellt. Je nach Bedarf an Genauigkeit können Objektdimensionen, Ausrichtungen und Unsicherheiten berücksichtigt werden. In simulierten Szenarien diente eine mit Monte-Carlo-Methoden berechnete Kollisionswahrscheinlichkeit als Referenz für die entwickelten Abschätzungen.

Anhang A

Herleitungen

Lemma A.1. *Bei einer Skalierung der Vorwärtsvariablen gemäß (3.48, 3.51) ergibt sich die Produktionswahrscheinlichkeit einer Beobachtungsfolge durch das HMM aus dem Produkt der Skalierungsfaktoren*

$$P(\mathbf{O} | \lambda) = \prod_{t=1}^T c_t. \quad (\text{A.1})$$

Beweis. Für die skalierte Vorwärtsvariablen (3.52, 3.49) gilt mit der Definition $\bar{\bar{\alpha}}_1 := \alpha_1$

$$\begin{aligned} \bar{\alpha}_1(i) &= \frac{\bar{\bar{\alpha}}_1(i)}{c_1} = \frac{\alpha_1(i)}{c_1} \\ \bar{\alpha}_2(i) &= \frac{\bar{\bar{\alpha}}_2(i)}{c_2} = \frac{\sum_{j=1}^N (\bar{\alpha}_1(j) a_{j,i}) b_i(O_2)}{c_2} = \frac{\sum_{j=1}^N (\alpha_1(j) a_{j,i}) b_i(O_2)}{c_1 c_2} = \frac{\alpha_2(i)}{c_1 c_2} \\ \bar{\alpha}_3(i) &= \frac{\bar{\bar{\alpha}}_3(i)}{c_3} = \frac{\sum_{j=1}^N (\bar{\alpha}_2(j) a_{j,i}) b_i(O_3)}{c_3} = \frac{\sum_{j=1}^N (\alpha_2(j) a_{j,i}) b_i(O_3)}{c_1 c_2 c_3} = \frac{\alpha_3(i)}{c_1 c_2 c_3} \\ &\vdots \\ \bar{\alpha}_T(i) &= \frac{\alpha_T(i)}{c_1 c_2 \dots c_T} \end{aligned}$$

Mit (3.13) und

$$\sum_{i=1}^N \bar{\alpha}_t(i) = \frac{\sum_{i=1}^N \bar{\bar{\alpha}}_t(i)}{c_t} = \frac{\sum_{i=1}^N \bar{\alpha}_t(i)}{\sum_{i=1}^N \bar{\bar{\alpha}}_t(i)} = 1$$

folgt

$$P(\mathbf{O} | \lambda) = \sum_{i=1}^N \alpha_T(i) = c_1 c_2 \dots c_T \sum_{i=1}^N \bar{\alpha}_T(i) = \prod_{t=1}^T c_t.$$

□

Lemma A.2. *Es sei ein parametrisiertes Hidden-Markov-Modell λ und eine Beobachtungsfolge $\mathbf{O} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T)$ gegeben. Die Emissionen seien multivariat normalverteilt modelliert.*

$$b_i(\mathbf{x}_t) \sim \mathcal{N}(\mathbf{x}_t; \mu, \Sigma)$$

Die Emissionsverteilungen sowie die Beobachtungsfolge werden in einem neuen Modell λ' der Koordinatentransformation \mathbf{C} unterzogen.

$$\mathbf{x}'_t = \mathbf{C} \mathbf{x}_t$$

$$b'_i(\mathbf{x}'_t) \sim \mathcal{N}(\mathbf{x}'_t; \mathbf{C} \mu, \mathbf{C} \Sigma \mathbf{C}^T)$$

$$\mathbf{O}' = (\mathbf{x}'_1, \mathbf{x}'_2, \dots, \mathbf{x}'_T)$$

Dann gilt für den Zusammenhang der Produktionswahrscheinlichkeiten der Modelle

$$P(\mathbf{O} | \lambda) = |\mathbf{C}|^T P(\mathbf{O}' | \lambda') \quad (\text{A.2})$$

Beweis. Der Wert einer normalverteilten Wahrscheinlichkeitsdichte ändert sich bei einer Skalierung der Zufallsvariablen wie folgt.

$$\begin{aligned} \mathcal{N}(\mathbf{x}'_t; \mathbf{C} \mu, \mathbf{C} \Sigma \mathbf{C}^T) &= \frac{1}{\sqrt{|2\pi \mathbf{C} \Sigma \mathbf{C}^T|}} \exp\left(-\frac{1}{2}(\mathbf{C} \mathbf{x} - \mathbf{C} \mu)^T (\mathbf{C} \Sigma \mathbf{C}^T)^{-1} (\mathbf{C} \mathbf{x} - \mathbf{C} \mu)\right) \\ &= \frac{1}{\sqrt{|\mathbf{C}| |2\pi \Sigma| |\mathbf{C}^T|}} \exp\left(-\frac{1}{2}(\mathbf{x} - \mu)^T \mathbf{C}^T \mathbf{C}^{T-1} \Sigma^{-1} \mathbf{C}^{-1} \mathbf{C} (\mathbf{x} - \mu)\right) \\ &= \frac{1}{|\mathbf{C}|} \frac{1}{\sqrt{|2\pi \Sigma|}} \exp\left(-\frac{1}{2}(\mathbf{x} - \mu)^T \Sigma^{-1} (\mathbf{x} - \mu)\right) \\ &= \frac{1}{|\mathbf{C}|} \mathcal{N}(\mathbf{x}_t; \mu, \Sigma) \end{aligned}$$

Für die Produktionswahrscheinlichkeit entlang eines festen Pfades \mathbf{s} gilt nach (3.8)

$$\begin{aligned}
 P(\mathbf{O}', \mathbf{s} | \lambda') &= \prod_{t=1}^T a_{s_{t-1}, s_t} b'_{s_t}(O'_t) \\
 &= \prod_{t=1}^T a_{s_{t-1}, s_t} \frac{1}{|\mathbf{C}|} b_{s_t}(O_t) \\
 &= \frac{1}{|\mathbf{C}|^T} \prod_{t=1}^T a_{s_{t-1}, s_t} b_{s_t}(O_t) \\
 &= \frac{1}{|\mathbf{C}|^T} P(\mathbf{O}, \mathbf{s} | \lambda)
 \end{aligned}$$

und damit für die Produktionswahrscheinlichkeit

$$\begin{aligned}
 P(\mathbf{O} | \lambda) &= \sum_{\mathbf{s}} P(\mathbf{O}, \mathbf{s} | \lambda) \\
 &= |\mathbf{C}|^T \sum_{\mathbf{s}} P(\mathbf{O}', \mathbf{s} | \lambda') \\
 &= |\mathbf{C}|^T P(\mathbf{O}' | \lambda')
 \end{aligned}$$

□

Lemma A.3. *Bei einer multivariaten Normalverteilung mit n Dimensionen ist die Wahrscheinlichkeit, dass sich eine Realisierung innerhalb eines $k\sigma$ Ellipsoids befindet, durch die kumulative Verteilungsfunktion der χ_n^2 -Verteilung an der Stelle k^2 gegeben.*

Beweis. Da eine Kovarianzmatrix aus Symmetriegründen immer durch Hauptachsentransformation diagonalisierbar ist, kann ohne Beschränkung der Allgemeinheit vorausgesetzt werden, dass die Kovarianzmatrix in Diagonalform vorliegt. Eine Translation des Mittelwertes in den Ursprung ist ebenfalls ohne Beschränkung der Allgemeinheit möglich.

$$\mathbf{\Sigma} = \text{diag}(\sigma_1^2, \dots, \sigma_n^2) \quad , \quad \boldsymbol{\mu} = \mathbf{0} \quad (\text{A.3})$$

Dann beschreibt eine Höhenlinie der quadrierten Mahalanobis-Distanz

$$\mathbf{x}^T \mathbf{\Sigma}^{-1} \mathbf{x} = \frac{x_1^2}{\sigma_1^2} + \frac{x_2^2}{\sigma_2^2} + \dots + \frac{x_n^2}{\sigma_n^2} \stackrel{!}{=} k^2 \quad (\text{A.4})$$

einen Ellipsoid mit um dem Faktor k gestreckten Halbachsen $\sigma_1, \dots, \sigma_n$. Die Wahrscheinlichkeit, dass eine Stichprobe sich innerhalb eines Ellipsoids mit um k gestreckten Halbachsen $\sigma_1, \dots, \sigma_n$ um den Erwartungswert befindet, ist also gleichbedeutend mit der Wahrscheinlichkeit, dass die quadrierte Mahalanobis-Distanz einen Wert kleiner k^2 liefert. Aufgrund der Skaleninvarianz der Mahalanobis-Distanz sind die bei einer Realisierung auftretenden Distanzen χ_n^2 verteilt. Dies gilt per Definition: Die Summe von n quadrierten normalverteilten Zufallsvariablen genügt einer χ^2 -Verteilung mit n Freiheitsgraden. Die gesuchte Wahrscheinlichkeit ergibt sich also als Auswertung der kumulativen Verteilungsfunktion F der χ^2 -Verteilung mit n Freiheitsgraden an der Stelle k^2 :

$$P(\text{Stichprobe innerhalb } k \sigma \text{ Ellipsoid}) = F_{\chi_n^2}(k^2) \quad (\text{A.5})$$

□

Nachfolgende Tabelle zeigt einige ausgewählte Wahrscheinlichkeiten, dass eine Stichprobe einer n -dimensionalen Normalverteilung sich in einem $k \sigma$ Ellipsoid um den Erwartungswert befindet:

$k \setminus n$	1	2	3	4	5
1	68,27 %	39,35 %	19,87 %	9,02 %	3,74 %
2	95,45 %	86,47 %	73,85 %	59,40 %	45,06 %
3	99,73 %	98,89 %	97,07 %	93,89 %	89,09 %

Bei höherdimensionalen Modellen verliert ein $k \sigma$ Ellipsoid für kleine Werte von k rapide an Aussagekraft, wie man in Abbildung A.1 sehen kann. Hier ist bei der Abschätzung von Vertrauensbereichen besondere Vorsicht geboten.

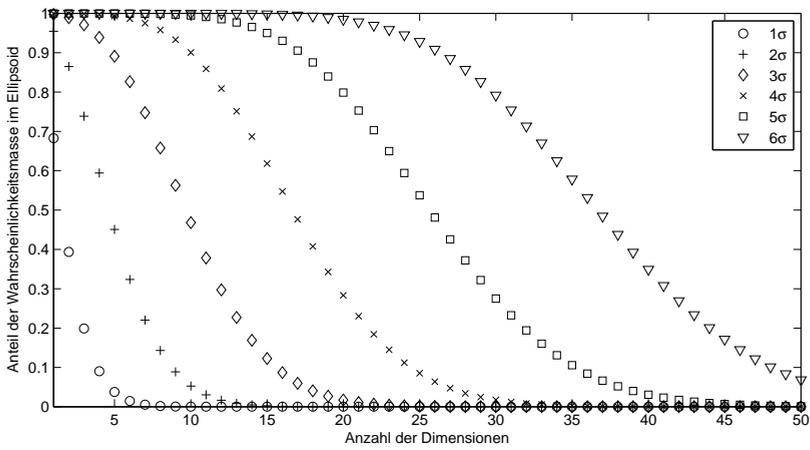


Abbildung A.1: Anteil der Wahrscheinlichkeitsmasse einer hochdimensionalen Normalverteilung in einem $k\sigma$ Ellipsoiden für einige Werte von k .

Anhang B

Grundbegriffe der Stochastik

Mit dem Begriff *Zufallsexperiment* wird ein Experiment mit zufälligem Ausgang bezeichnet. Ein *Ereignis* A entspricht einem Ergebnis oder einer Menge von Ergebnissen des Experiments. Die Menge aller möglichen Ergebnisse bildet den *Grundraum* Ω , und ist gleichzeitig das *sichere Ereignis*. Wird ein Zufallsexperiment N -mal durchgeführt und gezählt, wie oft m das Ereignis A aufgetreten ist, kann die *relative Häufigkeit* h_r des Ereignisses angegeben werden.

$$h_r(A) = \frac{m}{N} \tag{B.1}$$

Nach dem von Bernoulli zuerst untersuchten *Gesetz der großen Zahlen* nähert sich für eine große Anzahl von Versuchen die relative Häufigkeit der *Wahrscheinlichkeit* eines Ereignisses $P(A)$ an.¹ Die *Verbundwahrscheinlichkeit*, dass die beiden Ereignisse A und B gemeinsam auftreten, wird mit $P(A, B)$ bezeichnet. Die *bedingte Wahrscheinlichkeit*, dass Ereignis A auftritt unter dem Vorwissen, dass Ereignis B aufgetreten ist (oder sicher auftreten wird), wird mit $P(A | B)$ bezeichnet. Für den Zusammenhang zwischen bedingter und Verbundwahrscheinlichkeit gilt der *Multiplikationssatz*

$$P(A, B) = P(A | B) P(B). \tag{B.2}$$

Zwei Ereignisse A und B sind *stochastisch unabhängig*, wenn die Beziehung

$$P(A, B) = P(A) P(B) \tag{B.3}$$

¹In der Mathematik wird der Wahrscheinlichkeitsbegriff allerdings nicht anhand von Grenzwerten relativer Häufigkeiten, sondern axiomatisch nach Kolmogorow definiert. Der anschaulichere Übergang von relativen Häufigkeiten zu Wahrscheinlichkeiten ist jedoch für die mathematische Behandlung in dieser Arbeit ausreichend.

erfüllt ist. Ferner gilt für den Umgang mit bedingten Wahrscheinlichkeiten der *Satz von Bayes*.

$$P(B|A) = \frac{P(A|B)P(B)}{P(A)} \quad (\text{B.4})$$

Die Grundlage der mathematischen Behandlung von zufälligen Ereignissen bildet der Begriff der *Zufallsvariable*. Eine Abbildung von einem Grundraum Ω in die Menge der reellen Zahlen \mathbb{R}

$$X : \Omega \rightarrow \mathbb{R} \quad (\text{B.5})$$

heißt Zufallsvariable (auf Ω). Nimmt die Zufallsvariable nur endlich oder abzählbar unendlich viele verschiedene Werte an, spricht man von einer *diskreten Zufallsvariable*. Im Gegensatz dazu kann eine *kontinuierliche Zufallsvariable*² beliebige Werte aus \mathbb{R} annehmen.

Die Beschreibung der stochastischen Eigenschaften einer Zufallsvariablen kann über die (*kumulative*) *Verteilungsfunktion* erfolgen. Diese gibt die Wahrscheinlichkeit dafür an, dass eine Realisierung von X höchstens einen Wert von x ergibt.

$$F_X(x) = P(X \leq x) \quad (\text{B.6})$$

Bei diskreten Zufallsvariablen ergibt sich die Verteilungsfunktion aus der Summe der Wahrscheinlichkeiten aller Elementarereignisse $A_i \in \Omega$, denen ein Wert kleiner oder gleich x zugeordnet ist.

$$F_X(x) = P(X \leq x) = \sum_{i: x_i \leq x} P(A_i) = \sum_{i: x_i \leq x} p_i \quad (\text{B.7})$$

Bei kontinuierlichen Zufallsvariablen geht die Summation in eine Integration der *Wahrscheinlichkeitsdichtefunktion* p_X über.

$$F_X(x) = P(X \leq x) = \int_{-\infty}^x p_X(\xi) d\xi \quad (\text{B.8})$$

Bemerkenswert und für den Umgang mit Hidden-Markov-Modellen wichtig ist, dass die Werte der Wahrscheinlichkeitsdichtefunktion selbst keine Wahrscheinlichkeiten sind. Insbesondere kann die Dichtefunktion Werte größer eins annehmen.

²Statt *kontinuierlich* findet man in der Literatur auch den Begriff *stetig*.

Die Erweiterung auf vektorwertige Zufallsvariablen $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$ erfolgt auf Basis einer gemeinsamen Dichtefunktion $p_{\mathbf{X}}(x_1, x_2, \dots, x_n)$

$$F_{\mathbf{X}}(\mathbf{x}) = \int_{-\infty}^{x_n} \dots \int_{-\infty}^{x_2} \int_{-\infty}^{x_1} p_{\mathbf{X}}(\xi_1, \xi_2, \dots, \xi_n) d\xi_1 d\xi_2 \dots d\xi_n \quad (\text{B.9})$$

Die Verteilung heißt dann *multivariat*.

Der *Erwartungswert* $E\{X\}$ beschreibt den im statistischen Mittel zu erwartenden Wert einer Zufallsvariable. Er ergibt sich im Diskreten als

$$E\{X\} = \sum_{i=1}^{\infty} x_i p_i. \quad (\text{B.10})$$

Für kontinuierliche Zufallsvariablen ergibt er sich als erstes Moment der Dichtefunktion

$$E\{X\} = \int_{-\infty}^{\infty} x p_X(x) dx. \quad (\text{B.11})$$

Die Erweiterung auf einen Erwartungswertvektor μ im multivariaten Fall geschieht analog.

Die *Varianz* Var ist ein Maß für die Streuung einer Verteilung um ihren Mittelwert. Sie ist das zweite zentrale Moment einer Zufallsvariable.

$$\text{Var}\{X\} = E\{(X - E\{X\})^2\} \quad (\text{B.12})$$

Für den diskreten bzw. kontinuierlichen Fall resultieren daraus folgende Berechnungsvorschriften:

$$\text{Var}\{X\} = \sum_{i=1}^{\infty} (x_i - E\{X\})^2 p_i \quad (\text{B.13})$$

$$\text{Var}\{X\} = \int_{-\infty}^{\infty} (x - E\{X\})^2 p_X(x) dx \quad (\text{B.14})$$

Im multivariaten Fall verallgemeinert sich das Streuungsmaß zu einer *Kovarianzmatrix* Σ

$$\Sigma\{\mathbf{X}\} = E\{(\mathbf{X} - E\{\mathbf{X}\})(\mathbf{X} - E\{\mathbf{X}\})^T\}. \quad (\text{B.15})$$

Eine wichtige parametrische Verteilung ist die *Normalverteilung* \mathcal{N} , deren Dichtefunktion sich im multivariaten Fall mit dem Mittelwertvektor μ , der Kovarianzmatrix Σ und der Anzahl der Dimensionen k zu

$$\mathcal{N}(\mathbf{x}; \mu, \Sigma) = \frac{1}{\sqrt{|(2\pi)^k \Sigma|}} \exp\left(-\frac{1}{2}(\mathbf{x} - \mu)^T \Sigma^{-1}(\mathbf{x} - \mu)\right) \quad (\text{B.16})$$

ergibt. Durch *Mischverteilungen*, die aus gewichteten Summen von Normalverteilungen bestehen, lassen sich beliebige Verteilungen beliebig genau annähern.

Symbolverzeichnis

Abkürzungen

FDR	Falsch-Detektions-Rate
FPR	Falsch-Positiv-Rate
MPFZ	Minuten pro individuelm Falschalarm-Zeitschritt
RPR	Richtig-Positiv-Rate
CAN	Controller Area Network
DBN	Dynamisches bayessches Netz
HMM	Hidden-Markov-Modell
KFM	Kalman-Filter-Modell
PMD	Prädizierte minimale Distanz (Predicted Minimum Distance)
ROC	Receiver Operating Characteristic
TPMD	Zeit bis zur prädizierten minimalen Distanz (Time to Predicted Minimum Distance)
TTB	Zeit bis zum Bremsen (Time To Brake)
TTC	Zeit bis zur Kollision (Time To Collision)
TTI	Zeit bis zur Kreuzung (Time To Intersection)
TTK	Zeit bis zum Vollgas geben (Time To Kickdown)
TTR	Zeit zum Reagieren (Time To React)
TTS	Zeit bis zum Lenken (Time To Steer)
TTX	Zeit bis X (Time To X), Oberbegriff der zeitlichen Kenngrößen

Griechische Buchstaben

χ_n^2	Chi-Quadrat Verteilung mit n Freiheitsgraden
Σ	Kovarianzmatrix
ψ	Gierwinkel
σ	Varianz
Ω	Gesamter Zustandsraum

Hidden-Markov-Modelle

λ	Gesamtheit der Modell-Parameter
A	Matrix der Zustandsübergangswahrscheinlichkeiten
O	Vektor von Emissionen
π	Vektor von Startwahrscheinlichkeiten
s	Pfad von Zuständen durch ein Modell
s*	Bester Pfad durch das Modell nach Viterbi
b_j	Emissionswahrscheinlichkeitsdichteverteilung in Zustand j im Fall von diskreten Emissionen
B_j	Emissionswahrscheinlichkeitsverteilung in Zustand j im Fall von kontinuierlichen Emissionen
N	Anzahl der verborgenen Zustände
$P(\mathbf{O} \lambda)$	Produktionswahrscheinlichkeit
$P(\mathbf{O}, \mathbf{s}^* \lambda)$	Optimale Produktionswahrscheinlichkeit
T	Länge des Beobachtungsintervalls

Lateinische Buchstaben

\mathcal{C}	Kollisionsereignis
$\mathcal{N}(\mathbf{x}; \mu, \Sigma)$	Dichtefunktion der multivariaten Normalverteilung mit Mittelwertvektor μ und Kovarianzmatrix Σ an der Stelle \mathbf{x}
\mathcal{U}	Menge von zukünftigen Kontrolleingängen in die Fahrzeuge einer Szene
u	Eingangsvektor
v	Prozessrauschen
w	Messrauschen
x	Zustandsvektor
b	Objektbreite
l	Objektlänge
$P(\mathcal{C}) _t$	Kollisionswahrscheinlichkeit zum Zeitpunkt t
F	Kumulative Verteilungsfunktion

Manöver

ABVL	Abbiegevorgang nach links
ABVR	Abbiegevorgang nach rechts
FSWL	Fahrstreifenwechsel nach links
FSWR	Fahrstreifenwechsel nach rechts

Schreibweisen

$\text{diag}(\cdot)$	Diagonalmatrix
$\mathbf{x} \sim p(\mathbf{x})$	Die Zufallsvariable \mathbf{x} ist nach der Dichtefunktion p verteilt.

Literaturverzeichnis

- [AAZ13] Al-Sultan, S.; Al-Bayatti, A.H. und Zedan, H.: *Context-Aware Driver Behavior Detection System in Intelligent Transportation Systems*. In: *Vehicular Technology, IEEE Transactions on*, Band 62, Nr. 9, Seiten 4264–4275, 2013.
- [ADSH11] Aoude, G.S.; Desaraju, V.R.; Stephens, L.H. und How, J.P.: *Behavior classification algorithms at intersections and validation using naturalistic data*. In: *Intelligent Vehicles Symposium (IV), 2011 IEEE*, Seiten 601–606, 2011.
- [AFBM12] Aliane, N.; Fernandez, J.; Bemposta, S. und Mata, M.: *Driver behavior monitoring system based on traffic violation*. In: *Intelligent Vehicles Symposium (IV), 2012 IEEE*, Seiten 1096–1101, 2012.
- [AM13] Akrouf, B. und Mahdi, W.: *A visual based approach for drowsiness detection*. In: *Intelligent Vehicles Symposium (IV), 2013 IEEE*, Seiten 1324–1329, 2013.
- [AMT11] Angkititrakul, P.; Miyajima, C. und Takeda, K.: *Modeling and adaptation of stochastic driver-behavior model with application to car following*. In: *Intelligent Vehicles Symposium (IV), 2011 IEEE*, Seiten 814–819, 2011.
- [AMT12] Angkititrakul, P.; Miyajima, C. und Takeda, K.: *An improved driver-behavior model with combined individual and general driving characteristics*. In: *Intelligent Vehicles Symposium (IV), 2012 IEEE*, Seiten 426–431, 2012.
- [ANN11] Agamennoni, G.; Nieto, J.I. und Nebot, E.M.: *A bayesian approach for driving behavior inference*. In: *Intelligent Vehicles Symposium (IV), 2011 IEEE*, Seiten 595–600, 2011.
- [AON04] Arens, Michael; Ottlik, Artur und Nagel, Hans-Hellmut: *Using Behavioral Knowledge for Situated Prediction of Movements*. In: *27th Annual German Conference on AI*, Seiten 141–155, Ulm, 2004.
- [AWK⁺12] Althoff, D.; Werling, M.; Kaempchen, N.; Wollherr, D. und Buss, M.: *Lane-based safety assessment of road scenes using Inevitable Collision States*. In: *Intelligent Vehicles Symposium (IV), 2012 IEEE*, Seiten 31–36, 2012.

- [BBK04] Broadhurst, Adrian E.; Baker, Simon und Kanade, Takeo: *A Prediction and Planning Framework for Road Safety Analysis, Obstacle Avoidance and Driver Information*. In: *11th World Congress on Intelligent Transport Systems and Services*, Nagoya, Japan, 2004.
- [BBK05] Broadhurst, Adrian E.; Baker, Simon und Kanade, Takeo: *Monte Carlo Road Safety Reasoning*. In: *IEEE Intelligent Vehicles Symposium*, Las Vegas, USA, 2005.
- [BD06] Braess, Hans-Hermann und Donges, Edmund: *Technologien zur aktiven Sicherheit von Personenkraftwagen - Konsumierbare oder echte Verbesserungen?* In: *Aktive Sicherheit*, München, Germany, 2006.
- [BD08] Berndt, Holger und Dietmayer, Klaus C. J.: *Timing Analysis for Motorcycle Intersection Assistance Systems*. In: *15th World Congress on Intelligent Transport Systems*, New York, USA, 2008.
- [BD09] Berndt, Holger und Dietmayer, Klaus: *Driver Intention Inference with Vehicle Onboard Sensors*. In: *IEEE International Conference on Vehicular Electronics and Safety*, Pune, India, 2009.
- [BED08] Berndt, Holger; Emmert, Jörg und Dietmayer, Klaus C. J.: *Continuous Driver Intention Recognition with Hidden Markov Models*. In: *11th International IEEE Conference on Intelligent Transportation Systems ITSC*, Seiten 1189–1194, Beijing, China, 2008.
- [Bel57] Bellman, Richard Ernest: *Dynamic Programming*. Aus der Reihe *P (Rand Corporation)*. Princeton University Press, 1957.
- [BHK06] Buld, Susanne; Hoffmann, Sonja und Krüger, Hans-Peter: *Fahrerassistenz auf der Grundlage von Umgebungs- und Fahrervariablen*. In: *FAS Workshop Fahrerassistenzsysteme*, 2006.
- [BITC12] Butakov, V.; Ioannou, P.; Tippelhofer, M. und Camhi, J.: *Driver/vehicle response diagnostic system for vehicle following based on Gaussian Mixture Model*. In: *Decision and Control (CDC), 2012 IEEE 51st Annual Conference on*, Seiten 5649–5654, 2012.
- [BKL01] Bar-Shalom, Yaakov; Kirubarajan, Thiagalingam und Li, X.-Rong: *Estimation with Applications To Tracking and Navigation*. John Wiley & Sons, Inc., New York, NY, USA, 2001.
- [BL95] Bar-Shalom, Yaakov und Li, Xiao-Rong: *Multitarget-multisensor tracking: Principles and techniques*. Yaakov Bar-Shalom, Storrs (US), 1995.
- [BLNZ13] Bar, T.; Linke, D.; Nienhuser, D. und Zollner, J.M.: *Seen and missed traffic objects: A traffic object-specific awareness estimation*. In: *Intelligent Vehicles Symposium (IV), 2013 IEEE*, Seiten 31–36, 2013.
- [BMT11] Bando, T.; Miyahara, T. und Tamatsu, Y.: *Traffic interactions: Estimate driving behavior's influence*. In: *Intelligent Vehicles Symposium (IV), 2011 IEEE*, Seiten 546–551, 2011.

- [Bor13] Börger, Joachim: *Fahrerintentionserkennung und Kursprädiktion mit erweiterten maschinellen Lernverfahren*. Dissertation, Universität Ulm, 2013.
- [BP08] Bellis, E. und Page, J.: *National motor vehicle crash causation survey: SAS analytical users manual*. Techn. Ber. National Highway Traffic Safety Administration, Washington DC, 2008.
- [BPSW70] Baum, Leonard E.; Petrie, Ted; Soules, George und Weiss, Norman: *A Maximization Technique Occurring in the Statistical Analysis of Probabilistic Functions of Markov Chains*. In: *The Annals of Mathematical Statistics*, Band 41, Nr. 1, Seiten 164–171, 1970.
- [BRD09] Berndt, Holger; Rössler, Bernd und Dietmayer, Klaus: *Motorbike Intersection Assistance*. In: *6th International Workshop on Intelligent Transportation (WIT 2009)*, Hamburg, Germany, 2009.
- [BTDB11] Berthelot, A.; Tamke, A.; Dang, T. und Breuel, G.: *Handling uncertainties in criticality assessment*. In: *Intelligent Vehicles Symposium (IV), 2011 IEEE*, Seiten 571–576, 2011.
- [BTDB12] Berthelot, A.; Tamke, A.; Dang, T. und Breuel, G.: *A novel approach for the probabilistic computation of Time-To-Collision*. In: *Intelligent Vehicles Symposium (IV), 2012 IEEE*, Seiten 1173–1178, 2012.
- [BTNT13] Bando, T.; Takenaka, K.; Nagasaka, S. und Taniguchi, T.: *Unsupervised drive topic finding from driving behavioral data*. In: *Intelligent Vehicles Symposium (IV), 2013 IEEE*, Seiten 177–182, 2013.
- [BWD07] Berndt, Holger; Wender, Stefan und Dietmayer, Klaus C. J.: *Driver Braking Behavior during Intersection Approaches and Implications for Warning Strategies for Driver Assistant Systems*. In: *IEEE Intelligent Vehicles Symposium*, 2007.
- [BWKS13] Bonnin, S.; Weisswange, T.H.; Kummert, F. und Schmuuderich, J.: *Accurate behavior prediction on highways based on a systematic combination of classifiers*. In: *Intelligent Vehicles Symposium (IV), 2013 IEEE*, Seiten 242–249, 2013.
- [BYW13] Bi, Luzheng; Yang, Xuerui und Wang, Cuie: *Inferring driver intentions using a driver model based on queuing network*. In: *Intelligent Vehicles Symposium (IV), 2013 IEEE*, Seiten 1387–1391, 2013.
- [Dag05] Dagli, Ismail: *Erkennung von Einscherer-Situationen für Abstandsregeltempomaten*. Dissertation, Eberhard-Karls-Universität Tübingen, Fakultät für Informations- und Kognitionswissenschaften, 2005.
- [DBB02] Dagli, Ismail; Brost, Michael und Breuel, Gabi: *Action Recognition and Prediction for Driver Assistance Systems Using Dynamic Belief Networks*. In: *Lecture Notes in Artificial Intelligence, 2592*, Band 2592, Seiten 179–194, 2002.

- [DBS03] Dagli, Ismail; Breuel, Gabi und Schittenhelm, Helmut: *Einscherer-Erkennung mit erweiterter Umgebungserfassung – Eine Machbarkeitsstudie*. In: *FAS Workshop Fahrerassistenzsysteme*, Leinsweiler, Germany, 2003.
- [DBSS04] Dagli, Ismail; Breuel, Gabi; Schittenhelm, Helmut und Schanz, Alexander: *Cutting-in Vehicle Recognition for ACC Systems – Towards Feasible Situation Analysis Methodologies*. In: *IEEE Intelligent Vehicles Symposium*, Seiten 925–930, Parma, Italy, 2004.
- [DHS00] Duda, Richard O.; Hart, Peter E. und Stork, David G.: *Pattern Classification*. Wiley-Interscience Publication, 2000.
- [DLBB13] Daniel, J.; Lauffenburger, J.-P.; Bernet, S. und Basset, M.: *Driving risk assessment with belief functions*. In: *Intelligent Vehicles Symposium (IV), 2013 IEEE*, Seiten 690–695, 2013.
- [DMSS04] Dagan, E.; Mano, O.; Stein, G.P. und Shashua, A.: *Forward collision warning with a single camera*. In: *IEEE Intelligent Vehicles Symposium*, 2004.
- [DOT08] DOT: *Cooperative Intersection Collision Avoidance System Limited to Stop Sign and Traffic Signal Violations (CICAS-V)*. Techn. Ber. U.S. Department of Transportation, 2008.
- [DR02] Dagli, Ismail und Reichard, Dirk: *Motivation-Based Approach to Behavior Prediction*. In: *IEEE Intelligent Vehicles Symposium*, Versailles, France, 2002.
- [Dra11] Draxler, Markus: *Methoden zur Ermittlung der Kollisionswahrscheinlichkeit zweier Fahrzeuge*. Studienarbeit, Universität Ulm, 2011.
- [DT11] Doshi, A. und Trivedi, M.M.: *Tactical driver behavior prediction and intent inference: A review*. In: *Intelligent Transportation Systems (IT-SC), 2011 14th International IEEE Conference on*, Seiten 1892–1897, 2011.
- [EC11] Engel, D. und Curio, C.: *Pedestrian detectability: Predicting human perception performance with machine vision*. In: *Intelligent Vehicles Symposium (IV), 2011 IEEE*, Seiten 429–435, 2011.
- [Ehm01] Ehmanns, Dirk: *Simulationsmodell des menschlichen Spurwechselverhaltens*. In: *VDI/SAE/JSAE Gemeinschaftstagung, Der Fahrer im 21. Jahrhundert*, Berlin, Germany, 2001.
- [EK06] Ehmanns, Dirk und Kosch, Timo: *Fahrerassistenz im Kreuzungsbereich – erweiterte Möglichkeiten durch Kommunikationstechnologien*. In: *4. Workshop Fahrerassistenzsysteme FAS2006*, 2006.
- [EMAY12] Eren, H.; Makinist, S.; Akin, E. und Yilmaz, A.: *Estimating driving behavior by a smartphone*. In: *Intelligent Vehicles Symposium (IV), 2012 IEEE*, Seiten 234–239, 2012.

- [Emm08] Emmert, Jörg: *Fahrer-Intentionserkennung mit Hidden-Markov-Modellen unter Verwendung von Fahrzeugsignalen und Kartenmaterial*. Diplomarbeit, Universität Ulm, 2008.
- [EP08] Eidehall, Andreas und Petersson, Lars: *Statistical Threat Assessment for General Road Scenes Using Monte Carlo Sampling*. In: *IEEE Transactions on Intelligent Transportation Systems*, Band 9, Nr. 1, Seiten 137–147, 2008.
- [Fin03] Fink, Gernot A.: *Mustererkennung mit Markov-Modellen*. Aus der Reihe *Leitfäden der Informatik*. B. G. Teubner, Stuttgart – Leipzig – Wiesbaden, 2003.
- [Fis10] Fischer, Alexander: *Entwicklung eines Prädiktionsmodells für Fahrzeuge im Straßenverkehr*. Studienarbeit, Universität Ulm, 2010.
- [FM05] Färber, Berthold und Maurer, Markus: *Nutzer- und Nutzen-Parameter von Collision Warning und Collision Mitigation Systemen*. In: *FAS Workshop Fahrerassistenzsysteme*, Seiten 47–55, 2005.
- [FM06] Freyer, Jön und Maurer, Markus: *Analyse des Fahrverhalten unter dem Einfluss von Fahrerassistenzsystemen in Realfahrten*. In: *FAS Workshop Fahrerassistenzsysteme*, 2006.
- [FY13] Fukagawa, Y. und Yamada, K.: *Estimating driver awareness of pedestrians from driving behavior based on a probabilistic model*. In: *Intelligent Vehicles Symposium (IV), 2013 IEEE*, Seiten 1155–1160, 2013.
- [GDFD13] Graf, R.; Deusch, H.; Fritzsche, M. und Dietmayer, K.: *A learning concept for behavior prediction in traffic situations*. In: *Intelligent Vehicles Symposium (IV), 2013 IEEE*, Seiten 672–677, 2013.
- [Geo04] Georgii, Hans-Otto: *Stochastik: Einführung in die Wahrscheinlichkeitstheorie und Statistik*. Aus der Reihe *De Gruyter Lehrbuch*. De Gruyter, 2004.
- [Gum41] Gumbel, E. J.: *The Return Period of Flood Flows*. In: *Ann. Math. Statist.* Band 12, Nr. 2, Seiten 163–190, 1941.
- [HAH01] Huang, Xuedong; Acero, Alex und Hon, Hsiao-Wuen: *Spoken Language Processing: A Guide to Theory, Algorithm and System Development*. Prentice Hall, 2001.
- [HDT⁺10] Hülnhagen, T.; Dengler, I.; Tamke, A.; Dang, T. und Breuel, G.: *Maneuver recognition using probabilistic finite-state machines and fuzzy logic*. In: *Intelligent Vehicles Symposium (IV), 2010 IEEE*, Seiten 65–70, 2010.

- [HEH⁺10] Hermes, Christoph; Einhaus, Julian; Hahn, Markus; Wöhler, Christian und Kummert, Franz: *Vehicle Tracking and Motion Prediction in Complex Urban Scenarios*. In: *IEEE Intelligent Vehicles Symposium*, 2010.
- [Hen10] Henning, Matthias: *Preparation for lane change manoeuvres: Behavioural indicators and underlying cognitive processes*. Dissertation, TU Chemnitz, 2010.
- [Hen11] Henze, Norbert: *Stochastik für Einsteiger*. Vieweg+Teubner Verlag, 2011.
- [Hil12] Hillenbrand, M.: *Funktionale Sicherheit nach ISO 26262 in der Konzeptphase der Entwicklung von Elektrik/Elektronik Architekturen von Fahrzeugen*. Aus der Reihe *Steinbuch series on advances in information technology*. Universität Karlsruhe Universitätsbibliothek, 2012.
- [HKOB10] Homm, Florian; Kämpchen, Nico; Ota, Jeff und Burschka, Darius: *Efficient Occupancy Grid Computation on the GPU with Lidar and Radar for Road Boundary Detection*. In: *IEEE Intelligent Vehicles Symposium*, 2010.
- [HKS05] Hillenbrand, Jörg; Kroschel, Kristian und Schmid, Volker: *Situation Assessment Algorithm for a Collision Prevention Assistant*. In: *IEEE Intelligent Vehicles Symposium*, Las Vegas, USA, 2005.
- [HNR68] Hart, P.E.; Nilsson, N.J. und Raphael, B.: *A Formal Basis for the Heuristic Determination of Minimum Cost Paths*. In: *Systems Science and Cybernetics, IEEE Transactions on*, Band 4, Nr. 2, Seiten 100–107, 1968.
- [HSK06] Hillenbrand, J.; Spieker, A.M. und Kroschel, Kristian: *A Multilevel Collision Mitigation Approach mdash;Its Situation Assessment, Decision Making, and Performance Tradeoffs*. In: *Intelligent Transportation Systems, IEEE Transactions on*, Band 7, Nr. 4, Seiten 528–540, 2006.
- [HWB⁺11] Habenicht, S.; Winner, H.; Bone, S.; Sasse, F. und Korzenietz, P.: *A maneuver-based lane change assistance system*. In: *Intelligent Vehicles Symposium (IV), 2011 IEEE*, Seiten 375–380, 2011.
- [HWSK09] Hermes, Christoph; Wöhler, Christian; Schenk, Konrad und Kummert, Franz: *Long-term Vehicle Motion Prediction*. In: *IEEE Intelligent Vehicles Symposium*, Seiten 652–657, 2009.
- [ISO11] ISO: *ISO/FDIS 26262 Roadvehicles- Functional Safety, Part 1 - 10*. 2011.
- [JJG02] Jansson, Jonas; Johansson, Jonas und Gustafsson, Fredrik: *Decision making for collision avoidance systems*. In: *Society of Automotive Engineering SAE*, 2002.

- [KA06] Kumagai, Toru und Akamatsu, Motoyuki: *Prediction of Human Driving Behavior Using Dynamic Bayesian Networks*. In: *IEICE - Trans. Inf. Syst.* Band E89-D, Nr. 2, Seiten 857–860, 2006.
- [Kam07] Kämpchen, Nico: *Feature-Level Fusion of Laser Scanner and Video Data for Advanced Driver Assistance Systems*. Dissertation, Universität Ulm, 2007.
- [KE06] Kosch, Timo und Ehmans, Dirk: *Entwicklung von Kreuzungsassistenzsystemen und Funktionalitätserweiterungen durch den Einsatz von Kommunikationstechnologien*. In: *Aktive Sicherheit*, 2006.
- [KEW06] Klanner, Felix; Ehmans, Dirk und Winner, Hermann: *ConnectedDrive: Vorausschauende Kreuzungsassistenz*. In: *15. Aachener Kolloquium Fahrzeug- und Motorentchnik*, 2006.
- [KG12] Kusano, K.D. und Gabler, H.C.: *Identification of target populations for current active safety systems using driver behavior*. In: *Intelligent Vehicles Symposium (IV), 2012 IEEE*, Seiten 655–660, 2012.
- [Kla08] Klanner, Felix: *Entwicklung eines kommunikationsbasierten Querverkehrsassistenten im Fahrzeug*. Dissertation, Technische Universität Darmstadt, Fachgebiet Fahrzeugtechnik, 2008.
- [KPLL13] Kumar, P.; Perrollaz, M.; Lefevre, S. und Laugier, C.: *Learning-based approach for online lane change intention prediction*. In: *Intelligent Vehicles Symposium (IV), 2013 IEEE*, Seiten 797–802, 2013.
- [KR71] Kingsbury, N.G. und Rayner, P. J. W.: *Digital filtering using logarithmic arithmetic*. In: *Electronics Letters*, Band 7, Nr. 2, Seiten 56–58, 1971.
- [KS12] Krotak, T. und Simlova, M.: *The analysis of the acceleration of the vehicle for assessing the condition of the driver*. In: *Intelligent Vehicles Symposium (IV), 2012 IEEE*, Seiten 571–576, 2012.
- [KSD09] Kämpchen, Nico; Schiele, Bruno und Dietmayer, Klaus: *Situation Assessment of an Emergency Brake for Intersection Scenarios*. In: *IEEE Transactions on Intelligent Transportation Systems*, Band 10, Nr. 4, Seiten 678–687, 2009.
- [KTW08] Klanner, Felix; Thoma, Stephan und Winner, Hermann: *Fahrerverhaltensuntersuchungen und Mensch-Maschine-Interaktionskonzepte für die Kreuzungsassistenz*. In: *Aktive Sicherheit durch Fahrerassistenz*, 2008.
- [KWD⁺11] Kasper, D.; Weidl, G.; Dang, Thao u. a.: *Object-oriented Bayesian networks for detection of lane change maneuvers*. In: *Intelligent Vehicles Symposium (IV), 2011 IEEE*, Seiten 673–678, 2011.

- [KYSL00] Kuge, Nobuyuki; Yamamura, Tomohiro; Shimoyama, Osamu und Liu, Andrew: *A Driver Behavior Recognition Method Based on a Driver Model Framework*. In: *SAE World Congress*, Detroit, USA, 2000.
- [LAB⁺11] Levinson, J.; Askeland, J.; Becker, J. u. a.: *Towards fully autonomous driving: Systems and algorithms*. In: *Intelligent Vehicles Symposium (IV), 2011 IEEE*, Seiten 163–168, 2011.
- [LBKS12] Liebner, M.; Baumann, M.; Klanner, F. und Stiller, C.: *Driver intent inference at urban intersections using the intelligent driver model*. In: *Intelligent Vehicles Symposium (IV), 2012 IEEE*, Seiten 1162–1167, 2012.
- [LGTH05] Lattner, Andreas D.; Gehrke, Jan D.; Timm, Ingo J. und Herzog, Ott- hein: *A Knowledge-based Approach to Behavior Decision in Intelligent Vehicles*. In: *IEEE Intelligent Vehicles Symposium*, Seiten 466–471, Las Vegas, USA, 2005.
- [LLI11] Lefevre, S.; Laugier, C. und Ibanez-Guzman, J.: *Exploiting map in- formation for driver intention estimation at road intersections*. In: *Intelligent Vehicles Symposium (IV), 2011 IEEE*, Seiten 583–588, 2011.
- [LLI12] Lefevre, S.; Laugier, C. und Ibanez-Guzman, J.: *Risk assessment at road intersections: Comparing intention and expectation*. In: *Intelligent Vehicles Symposium (IV), 2012 IEEE*, Seiten 165–171, 2012.
- [LP97] Liu, Andrew und Pentland, Alex: *Towards real-time recognition of dri- ver intentions*. In: *IEEE Intelligent Transportation Systems Conference*, Boston, USA, 1997.
- [LRKS13] Liebner, M.; Ruhhammer, C.; Klanner, F. und Stiller, C.: *Generic driver intent inference based on parametric models*. In: *Intelligent Trans- portation Systems - (ITSC), 2013 16th International IEEE Conference on*, Seiten 268–275, 2013.
- [LW99] Ludmann, Jens und Weilkes, Michael: *Fahrermodelle als Hilfsmittel für die Entwicklung von ACC-Systemen*. In: *ATZ Automobiltechnische Zeitschrift*, Band 05/1999, Seiten 306–314, 1999.
- [MAB⁺11] Maile, M.; Ahmed-Zaid, F.; Bai, Sue u. a.: *Objective testing of a coope- rative intersection collision avoidance system for traffic signal and stop sign violation*. In: *Intelligent Vehicles Symposium (IV), 2011 IEEE*, Seiten 130–137, 2011.
- [Mag08] Mages, Mark Alexander: *Top-Down-Funktionsentwicklung eines Einbiege- und Kreuzenassistenten*. Dissertation, Technische Universität Darm- stadt, Fachgebiet Fahrzeugtechnik, 2008.

- [Mah09] Mählich, Mirko: *Filtersynthese zur simultanen Minimierung von Existenz-, Assoziations- und Zustandsunsicherheiten in der Fahrzeugumfelderfassung mit heterogenen Sensordaten*. Dissertation, Universität Ulm, 2009.
- [May04] Mayser, Christoph: *Fahrerassistenzsysteme zur Unterstützung der Längsregelung im ungebundenen Verkehr*. In: *Aktive Sicherheit*, 2004.
- [MDG⁺05] Mertz, Christoph; Duggins, David; Gowdy, Jay u. a.: *Collision Warning and Sensor Data Processing in Urban Areas*. In: *5th international conference on ITS telecommunications*, Seiten 73–78, 2005.
- [MDT11] Morris, B.; Doshi, A. und Trivedi, M.: *Lane change intent prediction for driver assistance: On-road design and evaluation*. In: *Intelligent Vehicles Symposium (IV), 2011 IEEE*, Seiten 895–901, 2011.
- [MEH04] Meitinger, Karl-Heinz; Ehmanns, Dirk und Heißling, Bernd: *Systematische Top-Down-Entwicklung von Kreuzungsassistenzsystemen: Beispiel Stop-Schild-Warnung*. In: *VDI/VW Gemeinschaftstagung Integrierte Sicherheit und Fahrerassistenzsysteme*, 2004.
- [Mer04] Mertz, Christoph: *A 2D Collision Warning Framework based on a Monte Carlo Approach*. In: *ITS America's 14th Annual Meeting and Exposition*, 2004.
- [MG13] Masala, G.L. und Grosso, E.: *Detecting driver inattention by rough iconic classification*. In: *Intelligent Vehicles Symposium (IV), 2013 IEEE*, Seiten 913–918, 2013.
- [MHE06] Meitinger, Karl-Heinz; Heißing, Bernd und Ehmanns, Dirk: *Linksabbiegeassistenz – Beispiel für die Top-Down-Entwicklung eines Aktiven Sicherheitssystems*. In: *Aktive Sicherheit*, 2006.
- [MHG06] Ming, Ji; Hazen, Timothy J. und Glass, James R.: *Combining Missing-Feature Theory, Speech Enhancement and Speaker-Dependent/-Independent Modeling for Speech Separation*. In: *Interspeech*, 2006.
- [MHW07] Mages, Mark Alexander; Hopstock, Matthias und Winner, Hermann: *Aktive Sicherheit durch Kreuzungsassistenz – Erkennung von Gefahrensituationen, Auswahl von Warnstrategien und Ableitung von Sensoranforderungen*. In: *VDI-Tagung Fahrer im 21. Jahrhundert*, 2007.
- [Mic85] Michon, John A.: *Human behavior and traffic safety*. In: Hrsg. von Evans, Leonard und Schwing, Richard C. Plenum Press, New York, 1985. Kap. A critical view of driver behavior models: What do we know, what should be do?, Seiten 485–520.
- [Mit04] Mitschke, Manfred: *Dynamik der Kraftfahrzeuge*. Springer, Berlin, 2004.

- [MLVH04] Miene, Andrea; Lattner, Andreas D.; Visser, Ubbo und Herzog, Otthein: *Dynamic-preserving Qualitative Motion Description for Intelligent Vehicles*. In: *IEEE Intelligent Vehicles Symposium*, Seiten 642–646, Parma, Italy, 2004.
- [MT06] McCall, J. C. und Trivedi, M. M.: *Human behavior based predictive brake assistance*. In: *IEEE Intelligent Vehicles Symposium*, Seiten 8–12, 2006.
- [MTBT02] Mayenobe, P.; Trassoudaine, L.; Bellet, T. und Tattegrain-Veste, H.: *Cognitive simulation of driver and cooperative driving assistance*. In: *IEEE Intelligent Vehicles Symposium*, Versailles, France, 2002.
- [Mun11] Munz, Michael: *Generisches Sensorfusionsframework zur gleichzeitigen Zustands- und Existenzschätzung für die Fahrzeugumfeldererkennung*. Dissertation, Universität Ulm, 2011.
- [Mur02a] Murphy, Kevin: *Dynamic Bayesian Networks: Representation, Inference and Learning*. Dissertation, University of California, Berkeley, 2002.
- [Mur02b] Murphy, Kevin: *Hidden semi-Markov models (segment models)*. Techn. Ber. Department of Computer Science, University of British Columbia, Canada, 2002.
- [MY11] Mabuchi, R. und Yamada, K.: *Study on driver-intent estimation at yellow traffic signal by using driving simulator*. In: *Intelligent Vehicles Symposium (IV), 2011 IEEE*, Seiten 95–100, 2011.
- [MY13] Mabuchi, R. und Yamada, K.: *Prediction of driver's stop or go at yellow traffic signal from vehicle behavior*. In: *Intelligent Vehicles Symposium (IV), 2013 IEEE*, Seiten 1161–1166, 2013.
- [NA03] Nagel, Hans-Hellmut und Arens, Michael: *Zur unscharf-metrisch-temporallogischen Spezifikation von Verkehrssituationen bei der Autobahnfahrt*. In: *FAS Workshop Fahrerassistenzsysteme*, Seiten 35–36, Leinsweiler, Germany, 2003.
- [Nag06] Nagel, Hans-Hellmut: *Zur Ergänzung induktiver FAS-Entwicklungen durch einen deduktiven Ansatz*. In: *FAS Workshop Fahrerassistenzsysteme*, 2006.
- [NK03] Neukum, Alex und Krüger, Hans-Peter: *Fahrerreaktionen bei Lenksystemstörungen – Untersuchungsmethodik und Bewertungskriterien*. In: *VDI-Berichte*, Band 1791, Seiten 297–318, 2003.
- [OC12] Osgouei, Reza Haghighi und Choi, Seungmoon: *Evaluation of driving skills using an HMM-based distance measure*. In: *Haptic Audio Visual Environments and Games (HAVE), 2012 IEEE International Workshop on*, Seiten 50–55, 2012.

- [OFKG11] Ortiz, M.G.; Fritsch, J.; Kummert, F. und Gepperth, A.: *Behavior prediction at multiple time-scales in inner-city scenarios*. In: *Intelligent Vehicles Symposium (IV), 2011 IEEE*, Seiten 1068–1073, 2011.
- [Ols03] Olsen, Erik Charles Buck: *Modeling Slow Lead Vehicle Lane Changing*. Dissertation, Virginia Polytechnic Institute und State University, 2003.
- [OSB04] Oppenheim, Alan V.; Schafer, Ronald W. und Buck, John R.: *Zeitdiskrete Signalverarbeitung*. Pearson Studium, 2004.
- [PD02] Pellkofer, M. und Dickmanns, E. D.: *Behavior Decision in Autonomous Vehicles*. In: *IEEE Intelligent Vehicles Symposium*, Versailles, France, 2002.
- [PH04] Pellicchia, A. und Hedelbrunner, J.: *Modeling Real Driving Behaviors through Attractor Dynamics for Motivation*. In: *IEEE Intelligent Vehicles Symposium*, Parma, Italy, 2004.
- [PL99] Pentland, Alex und Liu, Andrew: *Modeling and Prediction of Human Behavior*. In: *Neural Computation*, Band 11, Nr. 1, Seiten 229–242, 1999.
- [PTA⁺04] Polychronopoulos, A.; Tsogas, M.; Amditis, A. u. a.: *Dynamic situation and threat assessment for collision warning systems: the EUCLIDE approach*. In: *IEEE Intelligent Vehicles Symposium*, Parma, Italy, 2004.
- [Rab89] Rabiner, Lawrence R.: *A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition*. In: *Proceedings of the IEEE*, Band 77, Nr. 2, Seiten 257–286, 1989.
- [Ras83] Rasmussen, Jens: *Skills, rules, and knowledge: signals, signs, and symbols, and other distinctions in human performance models*. In: *IEEE Transactions on Systems, Man and Cybernetics*, Band 13, Nr. 3, Seiten 257–266, 1983.
- [RES13] Rano, I.; Edelbrunner, H. und Schoner, G.: *Naturalistic lane-keeping based on human driver data*. In: *Intelligent Vehicles Symposium (IV), 2013 IEEE*, Seiten 340–345, 2013.
- [RFL06] Rössler, Bernd; Fürstenberg, Kay und Lages, Ulrich: *Intersection Safety - the EC Project INTERSAFE*. In: *Advanced Microsystems for Automotive Applications*, Berlin, Germany, 2006.
- [RHW⁺12] Rodemerck, C.; Habenicht, S.; Weitzel, A.; Winner, H. und Schmitt, T.: *Development of a general criticality criterion for the risk estimation of driving situations and its application to a maneuver-based lane change assistance system*. In: *Intelligent Vehicles Symposium (IV), 2012 IEEE*, Seiten 264–269, 2012.
- [RJ86] Rabiner, Lawrence R. und Juang, B. H.: *An Introduction to Hidden Markov Models*. In: *IEEE ASSP Magazine*, Band 3, Seiten 4–16, 1986.

- [SA06] Straßberger, Markus und Adler, Christian: *Lokale Gefahrenwarnung in Fahrzeug-Ad-Hoc-Netzen – Eine umfassende Analyse und aktuelle Lösungsansätze*. In: *Aktive Sicherheit*, 2006.
- [SB11] Sandblom, F. und Brannstrom, M.: *Probabilistic threat assessment and driver modeling in collision avoidance systems*. In: *Intelligent Vehicles Symposium (IV), 2011 IEEE*, Seiten 914–919, 2011.
- [SBL01] Salvucci, Dario D.; Boer, E. R. und Liu, A.: *Toward an integrated model of driver behavior in a cognitive architecture*. In: *Transportation Research Record*, Band 1779, Seiten 9–16, 2001.
- [Sch07] Schaupp, Daniel: *Erstellung eines Frameworks zur Autofahrer-Intentionserkennung mit Hidden Markov Modellen*. Diplomarbeit, Universität Ulm, 2007.
- [SDC⁺10] Siordia, O.S.; de Diego, I.M.; Conde, C.; Reyes, G. und Cabello, E.: *Driving risk classification based on experts evaluation*. In: *Intelligent Vehicles Symposium (IV), 2010 IEEE*, Seiten 1098–1103, 2010.
- [SMB03] Schlenoff, Craig; Madhavan, Raj und Balakirsky, Stephen: *An Approach to Predicting the Location of Moving Objects During On-Road Navigation*. In: *IJCAI Workshop on Issues in Designing Physical Agents for Dynamic Real-Time Environments*, Seiten 71–79, Acapulco, Mexico, 2003.
- [SMKY07] Salvucci, Dario D.; Mandalia, Hiren M.; Kuge, Nobuyuki und Yamamura, Tomohiro: *Lane-Change Detection Using a Computational Driver Model*. In: *Human Factors*, 2007.
- [Sta13] Statistisches Bundesamt: *Verkehr auf einen Blick*. Fachserie 8, Reihe 7, Wiesbaden, Germany, 2013.
- [Sta14] Statistisches Bundesamt: *Verkehr – Verkehrsunfälle 2013*. Fachserie 8, Reihe 7, Wiesbaden, Germany, 2014.
- [TDB11] Tamke, A.; Dang, T. und Breuel, G.: *A flexible method for criticality assessment in driver assistance systems*. In: *Intelligent Vehicles Symposium (IV), 2011 IEEE*, Seiten 697–702, 2011.
- [TNH⁺12] Taniguchi, T.; Nagasaka, S.; Hitomi, K.; Chandrasiri, N.P. und Bando, T.: *Semiotic prediction of driving behavior using unsupervised double articulation analyzer*. In: *Intelligent Vehicles Symposium (IV), 2012 IEEE*, Seiten 849–854, 2012.
- [TYJ⁺13] Taib, R.; Yu, Kun; Jung, J.; Hess, A. und Maier, A.: *Human-centric analysis of driver inattention*. In: *Intelligent Vehicles Symposium (IV), 2013 IEEE*, Seiten 7–12, 2013.
- [Vep09] Vepa, Leo: *Videobasierte, echtzeitfähige Bestimmung der lateralen Fahrzeugposition durch Fahrspurerkennung*. Studienarbeit, Universität Ulm, 2009.

- [Vit67] Viterbi, Andrew James: *Error bounds for convolutional codes and an asymptotically optimum decoding algorithm*. In: *IEEE Transactions on Information Theory*, Band 13, Nr. 2, Seiten 260–269, 1967.
- [VR05] Vollrath, Marc und Rataj, Jürgen: *Virtual and Real Driving – Tools for the Design and Assessment of Driver Assistance*. In: *The 5th European Congress and Exhibition on Intelligent Transport Systems and Services HITS*, 2005.
- [VZV11] Varadarajan, Karthik Mahesh; Zhou, Kai und Vincze, Markus: *Mental state and behavior inference using Mirror Neuron System architecture for traffic/driver monitoring*. In: *Intelligent Vehicles Symposium (IV), 2011 IEEE*, Seiten 933–938, 2011.
- [WBF⁺13] Weisswange, T.H.; Bolder, B.; Fritsch, J.; Hasler, S. und Goerick, C.: *An integrated ADAS for assessing risky situations in urban driving*. In: *Intelligent Vehicles Symposium (IV), 2013 IEEE*, Seiten 292–297, 2013.
- [Wen08] Wender, Stefan: *Multisensorsystem zur erweiterten Fahrzeugumfelderfassung*. Dissertation, Universität Ulm, 2008.
- [WHKD12] Wiest, J.; Hoffken, M.; Kresel, U. und Dietmayer, K.: *Probabilistic trajectory prediction with Gaussian mixture models*. In: *Intelligent Vehicles Symposium (IV), 2012 IEEE*, Seiten 141–146, 2012.
- [WP05] Wegscheider, Michael und Prokop, Günther: *Modellbasierte Komfortbewertung von Fahrerassistenzsystemen*. In: *VDI-Berichte*, Band 1900, Seiten 17–36, 2005.
- [WSD07] Weiss, Thorsten; Schiele, Bruno und Dietmayer, Klaus: *Robust Driving Path Detection in Urban and Highway Scenarios Using a Laser Scanner and Online Occupancy Grids*. In: *IEEE Intelligent Vehicles Symposium*, 2007.
- [Wun07] Wünschmann, Jürgen: *Auswertung von Straßenkarten-Information für moderne Fahrerassistenzsysteme*. Studienarbeit, Universität Ulm, 2007.
- [YYFK03] Yang, Lee C.; Yang, Ji Hyun; Feron, Eric M. und Kulkarni, Vishwesh: *Development of a Performance-Based Approach for a Rear-End Collision Warning and Avoidance System for Automobiles*. In: *IEEE Intelligent Vehicles Symposium*, Columbus, USA, 2003.
- [YZBZ13] Yao, Wen; Zhao, Huijing; Bonnifait, P. und Zha, Hongbin: *Lane change trajectory prediction by using recorded human driving data*. In: *Intelligent Vehicles Symposium (IV), 2013 IEEE*, Seiten 430–436, 2013.
- [YZDZ12] Yao, Wen; Zhao, Huijing; Davoine, F. und Zha, Hongbin: *Learning lane change trajectories from on-road driving data*. In: *Intelligent Vehicles Symposium (IV), 2012 IEEE*, Seiten 885–890, 2012.

- [Zom91] Zomotor, Adam: *Fahrwerktechnik: Fahrverhalten*. Hrsg. von Reimpell, JörnSEN. Vogel, 1991.
- [ZQL⁺14] Zhang, Hui; Qiu, ShaoBo; Li, Yang u. a.: *Study on Lane Change Intentions of Chinese Drivers Based on Real-Road Driving Data*. In: *FISITA World Automotive Congress*, 2014.

Publikationen

Teile dieser Dissertation wurden bereits in folgenden Fachbeiträgen veröffentlicht:

Berndt, Holger und Dietmayer, Klaus C. J.: *Timing Analysis for Motorcycle Intersection Assistance Systems*. In: *15th World Congress on Intelligent Transport Systems*, New York, USA, 2008.

Berndt, Holger und Dietmayer, Klaus: *Driver Intention Inference with Vehicle Onboard Sensors*. In: *IEEE International Conference on Vehicular Electronics and Safety*, Pune, India, 2009.

Berndt, Holger; Emmert, Jörg und Dietmayer, Klaus C. J.: *Continuous Driver Intention Recognition with Hidden Markov Models*. In: *11th International IEEE Conference on Intelligent Transportation Systems ITSC*, Seiten 1189–1194, Beijing, China, 2008.

Berndt, Holger; Rössler, Bernd und Dietmayer, Klaus: *Motorbike Intersection Assistance*. In: *6th International Workshop on Intelligent Transportation (WIT 2009)*, Hamburg, Germany, 2009.

Berndt, Holger; Wender, Stefan und Dietmayer, Klaus C. J.: *Driver Braking Behavior during Intersection Approaches and Implications for Warning Strategies for Driver Assistant Systems*. In: *IEEE Intelligent Vehicles Symposium*, 2007.

Betreute studentische Arbeiten

Draxler, Markus: *Methoden zur Ermittlung der Kollisionswahrscheinlichkeit zweier Fahrzeuge*. Studienarbeit, Universität Ulm, 2011.

Emmert, Jörg: *Fahrer-Intentionserkennung mit Hidden-Markov-Modellen unter Verwendung von Fahrzeugsignalen und Kartenmaterial*. Diplomarbeit, Universität Ulm, 2008.

Fischer, Alexander: *Entwicklung eines Prädiktionsmodells für Fahrzeuge im Straßenverkehr*. Studienarbeit, Universität Ulm, 2010.

Schaupp, Daniel: *Erstellung eines Frameworks zur Autofahrer-Intentionserkennung mit Hidden Markov Modellen*. Diplomarbeit, Universität Ulm, 2007.

Vepa, Leo: *Videobasierte, echtzeitfähige Bestimmung der lateralen Fahrzeugposition durch Fahrspurerkennung*. Studienarbeit, Universität Ulm, 2009.

Wünschmann, Jürgen: *Auswertung von Straßenkarten-Information für moderne Fahrerassistenzsysteme*. Studienarbeit, Universität Ulm, 2007.

