

Kartenbasierte Fahrzeugprädiktion in urbanen Kreuzungsszenarien

Zur Erlangung des akademischen Grades eines

**DOKTORS DER INGENIEURWISSENSCHAFTEN
(Dr.-Ing.)**

von der KIT-Fakultät für Maschinenbau des
Karlsruher Instituts für Technologie (KIT)

angenommene

DISSERTATION

von

Jannik Markus Quehl, M.Sc.

geb. in Konstanz

Tag der mündlichen Prüfung:

04.02.2025

Hauptreferent:

Prof. Dr.-Ing. Christoph Stiller

Korreferent:

Prof. Dr.-Ing. Michael Heizmann

Danksagung

Diese Dissertation entstand im Wesentlichen während meiner Zeit als wissenschaftlicher Mitarbeiter am Institut für Mess- und Regelungstechnik. Ohne die vielfältige Unterstützung, die ich dort erfahren habe, wäre diese Arbeit nicht möglich gewesen.

Insbesondere hervorheben möchte ich in diesem Zusammenhang meinen Doktorvater, Herrn Prof. Dr.-Ing. Christoph Stiller, der mit seinem Institut großartige Rahmenbedingungen für das wissenschaftliche Arbeiten an autonomen Fahrzeugen mit starkem Praxisbezug bietet. Die Möglichkeit, meine Arbeit nicht nur auf Datensätzen, sondern auch auf realen, selbstfahrenden Fahrzeugen testen zu können, stellte eine Lerngelegenheit dar, wie sie nur selten an deutschen Hochschulen zu finden ist. Ebenso danke ich Herrn Stiller für die gute Betreuung, die angeregten Diskussionen auf Sommerseminaren sowie das eine oder andere Schachspiel.

Des Weiteren danke ich Herrn Prof. Dr.-Ing. Michael Heizmann für die Übernahme des Korreferats sowie Herrn Prof. Dr.-Ing. Marcus Geimer für den Vorsitz meiner mündlichen Prüfung. Mein besonderer Dank gilt Martin Lauer für die direkte Betreuung, das wöchentliche Feedback und die gemeinsame Zeit während meiner Tätigkeit als Übungsleiter für Machine Vision.

Ein besonderer Dank geht auch an meine Kolleginnen und Kollegen am MRT, von denen ich heute viele zu meinen Freunden zählen darf. Ohne euch wäre meine Zeit am MRT einfach nur Arbeit gewesen. Ihr habt sie mit Freude, Spaß und Tischtennis gefüllt, und so habe ich mich fast jeden Tag auf die Stunden im Büro gefreut. Besonders erwähnen möchte ich meine langjährigen, mir spielerisch beinahe ebenbürtigen Tischtennispartner und Freunde Johannes und Frank. Ebenso danke ich meinen Freunden und Kollegen Sven und Florian, mit denen ich mir lange ein Büro sowie so manchen gemeinsamen Abend geteilt habe. Hendrik, Şahin und Jan - ihr habt meinen Weg von Anfang bis Ende begleitet. Und natürlich danke ich jedem weiteren Kollegen und jeder

Kollegin, der oder die sich mit mir fachlich und unterhaltsam über meine Arbeit, das MRT, das Leben und die Welt ausgetauscht hat.

Last but not least möchte ich mich herzlich beim Sekretariat bedanken. Dank Erna, Alexandra und Frau Klimesch konnte ich mich stets auf das Wesentliche konzentrieren, ohne dass dabei so „nebensächliche“ Dinge wie die Verlängerung meines Arbeitsvertrags oder die Anmeldung zur Promotion übersehen wurden.

Der letzte Abschnitt dieser Danksagung gilt meiner Familie und insbesondere meiner Frau Josie. Die Zeit meiner Promotion war oft nicht leicht. Meine Zeit am MRT wurde leider von zwei Krebserkrankungen sowie der Corona-Pandemie überschattet. Doch meine Frau und meine Familie standen mir in diesen schweren Zeiten immer zur Seite, halfen mir durchzuhalten und erinnerten mich in den guten Momenten auch daran, auf mich selbst zu achten und nicht nur auf die Arbeit. Zuletzt hat mir meine Frau unsere beiden wunderbaren Töchter Kiara und Sophie geschenkt, und dafür kann ich gar nicht genug danken.

Vielen Dank!

Stutensee im Juli 2025

Jannik

Zusammenfassung

Die Verhaltensvorhersage anderer Verkehrsteilnehmer ist ein essenzieller Bestandteil von Softwaresystemen, die das hochautomatisierte Fahren ermöglichen. Mit einer solchen Vorhersage ist es einem automatischen Fahrzeug möglich, die eigene Fahrweise vorausschauend zu planen und dadurch sowohl den Verkehrsfluss als auch den Komfort für die Passagiere zu verbessern.

Die vorliegende Arbeit stellt ein System zur Vorhersage von Fahrzeugbewegung in Kreuzungssituationen, wie sie überwiegend in urbanen Umgebungen auftreten, vor. Um die Vorhersage zu treffen, werden zunächst die zu erwartenden Abhängigkeiten zwischen den Verhaltensweisen aller Fahrzeuge analysiert und in einem Abhängigkeitsgraphen hierarchisch modelliert. Hierfür wird eine hochgenaue Planungskarte, inklusive der geltenden Verkehrsregeln, sowie die beobachtbaren physischen Zustände der Fahrzeuge verwendet. Basierend auf diesem Abhängigkeitsgraphen werden Simulationen durchgeführt, indem ein Planungsalgorithmus für die einzelnen Fahrzeuge angewandt wird, wodurch mögliche Fahrzeugbewegungen identifiziert werden. Durch einen Abgleich des tatsächlich eintreffenden Verhaltens des betrachteten Fahrzeugs mit den Simulationsergebnissen wird eine Schätzung der Intentionen des Fahrzeugs mit einem nicht-stationären Hidden Markov-Modell durchgeführt. Die so geschätzten Wahrscheinlichkeiten für die jeweiligen Intentionen gemeinsam mit den simulierten Trajektorien der Fahrzeuge bilden das Ergebnis der Prädiktion.

Die einzelnen Verarbeitungsschritte des Systems – die Abhängigkeitsanalyse, die Trajektorienprädiktion und die Intentionsschätzung – werden separat voneinander anhand von geeigneten Szenarien aus öffentlichen Datensätzen qualitativ und quantitativ evaluiert. Hierfür werden sowohl geeignete Metriken aus der Literatur als auch eigene Metriken angewendet. Die Ergebnisse dieser Experimente zeigen, dass das vorgestellte System unter bestimmten Annahmen gut geeignet ist, die Intentionen anderer Fahrzeuge zu schätzen und deren Verhalten vorherzusagen.

Inhaltsverzeichnis

| | |
|---|------------|
| Danksagung | i |
| Zusammenfassung | iii |
| Abkürzungen und Symbole | vii |
| 1 Einleitung | 1 |
| 1.1 Motivation und Anforderungen | 2 |
| 1.2 Wissenschaftliche Beiträge dieser Arbeit | 4 |
| 1.3 Aufbau dieser Arbeit | 5 |
| 2 Einordnung in den Stand der Forschung | 7 |
| 2.1 Modellierung von menschlichem Fahrverhalten | 7 |
| 2.2 Intentionsschätzung von Fahrzeugen | 11 |
| 2.3 Prädiktion von menschlichem Fahrverhalten im Straßenverkehr | 13 |
| 2.4 Trajektorienprädiktion für Fahrzeuge | 15 |
| 3 Modellierung von Fahrzeuginteraktionen | 19 |
| 3.1 Einführung in Interaktionen | 19 |
| 3.2 Interaktions- und Entscheidungspunkte | 21 |
| 3.3 Verarbeitung von Karteninformationen | 24 |
| 3.4 Verkehrsregeln | 27 |
| 3.5 Abhängigkeitsgraphen | 29 |
| 3.6 Hierarchische Strukturierung von Abhängigkeitsrelationen . | 33 |
| 3.7 Bewertung von Abhängigkeitsrelationen | 38 |
| 4 Trajektorienprädiktion | 41 |
| 4.1 Planungsbasierte Prädiktion | 41 |

| | | |
|----------|--|------------|
| 4.2 | Komplexität von interaktiven Prädiktionsansätzen | 44 |
| 4.3 | Prädiktionsmodell | 46 |
| 4.4 | Abbildung von Interaktionen im Prädiktionsmodell | 49 |
| 4.5 | Validierung von Trajektorien | 53 |
| 5 | Intentionsschätzung | 55 |
| 5.1 | Intentionsschätzung mit Hidden Markov Models | 55 |
| 5.2 | Forward-Algorithmus | 59 |
| 5.3 | Beobachtungsmodell | 61 |
| 5.4 | Zustandsraum | 66 |
| 5.5 | Nicht-stationäre Hidden Markov Models | 70 |
| 5.6 | Nicht-stationärer Zustandsraum | 71 |
| 5.7 | Markov-Annahmen im nicht-stationären Modell | 75 |
| 6 | Experimente | 77 |
| 6.1 | Systemarchitektur | 77 |
| 6.2 | Datensätze | 79 |
| 6.3 | Evaluierung des Interaktionsmodells | 82 |
| 6.4 | Evaluierung der Trajektorienprädiktion | 84 |
| 6.5 | Evaluierung der Intentionsschätzung | 87 |
| 6.6 | Diskussion der Ergebnisse | 92 |
| 7 | Schlussfolgerungen und Ausblick | 95 |
| 7.1 | Zusammenfassung | 95 |
| 7.2 | Ausblick | 97 |
| A | Anhang | 99 |
| | Literaturverzeichnis | 109 |
| | Eigene Veröffentlichungen | 117 |
| | Betreute Abschlussarbeiten | 119 |

Abkürzungen und Symbole

Abkürzungen

| | |
|--------------|---|
| BN | Bayessches Netz |
| DFS | Tiefensuche (Depth First Search) |
| FAS | Fahrerassistenzsystem |
| HMM | Hidden Markov Model |
| IDM | Intelligent Driver Model |
| KNN | Künstliche neuronale Netze |
| MDP | Markov Entscheidungsprozess (Markov Decision Process) |
| MRT | Institut für Mess- und Regelungstechnik |
| NSHMM | Nicht-stationäres Hidden Markov Model |
| POMDP | Partiell beobachtbarer Markov Entscheidungsprozess (Partially Observable Markov Decision Process) |
| POSG | Partiell beobachtbares stochastisches Spiel (Partially Observable Stochastic Game) |
| RF | Random Forest |
| SVM | Support Vector Machine |
| WDF | Wahrscheinlichkeitsdichtefunktion |

Operatoren und Notation

| | |
|------------------|------------------|
| x | Skalare Variable |
| \mathbf{x} | Vektor-Variable |
| X | Zufallsvariablen |
| V, \mathcal{K} | Mengen |

| | |
|----------------------|--|
| $f(\cdot)$ | Skalare Funktion |
| $ V $ | Kardinalität einer Menge |
| $\ \boldsymbol{p}\ $ | Euklidische Norm eines Vektors |
| $P(x)$ | Wahrscheinlichkeit für Ereignis x |
| $P(x y)$ | Bedingte Wahrscheinlichkeit für Ereignis x gegeben, dass Ereignis y eintritt |
| $P(x, y)$ | Wahrscheinlichkeit, dass sowohl Ereignis x als auch Ereignis y eintreten |

1 Einleitung

Bereits mit der ersten Konzipierung von Automobilen beginnend fand eine stetige Entwicklung darin statt, das Fahren von Autos immer einfacher, komfortabler und sicherer zu gestalten. Teil dieser Entwicklungen sind die Fahrerassistenzsysteme (FAS), welche Teile der Aufgaben, die der Fahrer ursprünglich allein bewältigen musste, durch technologische Unterstützung vereinfachen oder vollständig übernehmen. Unter den Begriff Fahrerassistenzsysteme fallen eine Vielzahl an Funktionen, die aus einem modernen Auto kaum noch wegzudenken sind, wie Antiblockiersysteme, Fahrdynamikregelung, der (Abstandshalte-)Tempomat und Spurhalteassistenzen. Insbesondere in den letzten Jahren ist hierbei zu beobachten, dass diese Systeme immer größere Anteile der Aufgaben des Fahrers übernehmen können. Dies geht hin bis zu einem Grad, dass sich modernste Serienfahrzeuge in bestimmten Situationen ohne Fahrerinput verkehrsgerecht verhalten können.

Diese immer größer werdenden Schritte in Richtung Vollautomatisierung der Fahrzeuge werden durch große Fortschritte in der Sensortechnik, der Rechenleistung von Fahrzeugcomputern und der Algorithmik ermöglicht. Ein großes, noch zu bewältigendes Hindernis auf dem Weg zur Vollautomatisierung ist die Interaktion mit anderen und insbesondere menschlichen Verkehrsteilnehmern. Da diese im Allgemeinen keine für ein FAS verwertbaren Informationen über ihre Ziele oder bevorstehenden Aktionen liefern, ist es, um sinnvolle und natürlich wirkende Interaktionen mit diesen zu ermöglichen, notwendig, diese Informationen zu schätzen und vorherzusagen. Mit der Fragestellung, wie sich diese Schätzung der unvollständig vorliegenden Informationen über andere Fahrzeuge sowie die Prädiktion des Verhaltens dieser Fahrzeuge basierend auf diesen Schätzungen umsetzen lässt, beschäftigt sich die vorliegende Dissertation.

1.1 Motivation und Anforderungen

Jede Person, die in Deutschland ihren Führerschein macht, bekommt bereits in der Fahrschule die „vorausschauende Fahrweise“ als anzustrebendes Ideal präsentiert. Gemeint ist mit diesem Begriff, dass ein Fahrer stets Überblick über das gesamte Verkehrsgeschehen haben sollte, um die Absichten anderer Verkehrsteilnehmer oder andere Änderungen an der Verkehrssituation frühzeitig erkennen und sein Verhalten entsprechend anpassen zu können.

Soll sich ein automatisiertes Fahrzeug ähnlich verhalten, wie es ein menschlicher Fahrer tun würde, so muss ein algorithmisches Äquivalent zu diesem Vorgang konzipiert und umgesetzt werden. Hier setzt diese Dissertation an, deren Ziel es ist, ein Softwaresystem zu beschreiben, welches aus ähnlichen Informationen, wie sie dem Menschen zur Verfügung stehen, diese Aufgabe löst. Hierfür erkennt das System für alle anderen Fahrzeuge die durch die Verkehrsordnung erlaubten Verhaltensweisen und sagt vorher, welche von diesen am wahrscheinlichsten eintreten werden. Um dies zu realisieren, müssen dem Fahrzeug dieselben Informationen durch Fahrzeugsensorik über den Verlauf der Verkehrssituation bereitgestellt werden, die menschliche Fahrer benutzen, um vorausschauend zu fahren. Bei diesen Informationen handelt es sich im Wesentlichen um die Position des eigenen Fahrzeugs und die Positionen anderer Verkehrsteilnehmer, um die Straßentopologie und um die für die Situation relevanten Verkehrsregeln. Es wird hier davon ausgegangen, dass diese Informationen bereits vorliegen. Dies bedeutet, dass durch eine Kombination von Perzeptions- und Lokalisierungsalgorithmen alle für die Situation relevanten Fahrzeuge wahrgenommen wurden und dass eine Planungskarte vorliegt, aus welcher die relevanten Verkehrsregeln inferiert werden können. Eigene Vorarbeiten des Autors zu den Themen Perception anderer Verkehrsteilnehmer und Erkennen von Straßentopologien finden sich in [QHWL18, QYW⁺19] und [BQB18].

Neben den soeben beschriebenen Voraussetzungen an die Datenbasis dieser Arbeit ergeben sich ebenfalls Anforderungen an die Ergebnisse und Funktionsweise des hier entwickelten Systems. Wie bereits Wirth [Wir23] zuvor darlegte, ergaben sich in Zusammenarbeit mit auf Verhaltensplanung spezialisierten wissenschaftlichen Mitarbeitern am MRT die folgenden Anforderungen:

Unsicherheitsschätzung. Da sich die Vorhersage von Fahrzeugverhalten auf die Zukunft bezieht, kann nie vollständige Sicherheit darüber herrschen, ob eine Vorhersage genauso eintreffen wird, wie sie gemacht wurde, oder nicht. Ebenso bestehen Unsicherheiten in der Schätzung über den aktuellen Zustand (die Intentionen) der anderen Verkehrsteilnehmer. Damit solche Unsicherheiten sinnvoll in der Planung des eigenen Verhaltens berücksichtigt werden können, ist es notwendig, diese Unsicherheiten zu schätzen und neben dem eigentlichen Ergebnis auszugeben.

Multimodalität. In interaktiven Situationen des Straßenverkehrs unterscheiden sich die möglichen Verhaltensweisen üblicherweise nicht nur in der Art der Ausführung eines bestimmten Manövers, sondern ebenfalls in den durchzuführenden Manövern selbst. Dies bedeutet, dass eine gute Vorhersage dies berücksichtigen und jede der Möglichkeiten vorhersagen sollte.

Abhängigkeitsmodellierung. Die Angabe der Zusammenhänge zwischen den Verhaltensweisen verschiedener Fahrzeuge kann einen großen Mehrwert für die Verhaltensplanung bringen. Fahren beispielsweise zwei Fahrzeuge auf eine Kreuzung zu, so könnten die Wahrscheinlichkeiten beider Fahrzeuge stehenzubleiben oder durchzufahren auf 50% geschätzt werden. Daraus folgt jedoch mitnichten, dass eine Wahrscheinlichkeit von 25% besteht, dass beide Fahrzeuge zugleich auf die Kreuzung fahren, oder beide Fahrzeuge stehen bleiben, wie unter statistischer Unabhängigkeit angenommen werden könnte. Um die Wahrscheinlichkeit, dass die Mitte der Kreuzung zu einem gegebenen Zeitpunkt befahren wird, zu berechnen, ist daher Wissen über den Zusammenhang der jeweiligen Verhaltensweisen notwendig.

Effizienz. Ein Prädiktionsalgorithmus zur Anwendung im Fahrzeug muss effizient sein. Zum einen kann ein Softwaresystem zur Vorhersage von Sachverhalten nur dann einen Mehrwert liefern, wenn das System die Berechnungsergebnisse erheblich früher ausgibt, als diese beobachtet werden können. Zum anderen liefert die Perzeption kontinuierlich neue Informationen, welche in die Vorhersage einfließen sollten. Daher sollte ein Prädiktionssystem mit einer ähnlichen Rate wie die einkommenden Informationen die Vorhersageergebnisse mit geringer Latenz ausgeben können.

Generalisierung. Damit das zu automatisierende Fahrzeug in möglichst vielen Situationen sinnvolle Entscheidungen treffen kann, sollte jeder Teil der Verarbeitungskette und somit auch die Fahrzeugprädiktion in möglichst vielen Situationen sinnvolle Vorhersagen treffen können. Daher sollten Prädiktionsansätze möglichst allgemein formuliert und nicht nur auf einzelne Szenarien zugeschnitten werden.

Umfangreiche Informationsweitergabe. Da die Verhaltensplanung in ihrer Essenz nahe mit der Verhaltensprädiktion verwandt ist, sind viele in der Prädiktion gewonnenen Informationen nützlich für Planungsalgorithmen. Ein guter Prädiktionsansatz sollte daher alle Informationen weitergeben, die geschätzt und/oder präzidiert werden. Insbesondere handelt es sich hierbei sowohl um die geschätzten Intentionen der anderen Fahrzeuge auf Manöver-Ebene als auch die basierend auf diesen Manövern errechneten zukünftigen Trajektorien der einzelnen Fahrzeuge.

1.2 Wissenschaftliche Beiträge dieser Arbeit

Das Softwaresystem, welches im Kontext dieser Arbeit entwickelt wurde, orientiert sich im Wesentlichen an den oben angeführten Anforderungen. Die so gewonnenen Ergebnisse liefern hierbei die folgenden wissenschaftlichen Beiträge:

1. Eine automatisierte und planungskartenbasierte Interaktionsanalyse für Fahrzeuge. Das System erkennt, welche Fahrzeuge miteinander, unter Einhaltung der geltenden Verkehrsvorschriften, innerhalb eines Prädiktionshorizonts interagieren können und werden.
2. Ein dualer Prädiktionsansatz für Trajektorien und Intentionen. Das System schätzt zunächst die Intentionen der einzelnen Fahrzeuge und liefert basierend auf diesen Schätzungen Prädiktionen der Fahrzeugtrajektorien.
3. Eine Methode für die modulare Kombination von Intentionsschätzung und Trajektorienprädiktion. Diese Arbeit zeigt die Zusammenhänge zwischen beiden Disziplinen auf und beschreibt, wie diese miteinander

kombiniert werden können. Insbesondere ist die hier vorgestellte Intentionsschätzung nicht maßgeblich von der Art des für die Trajektorienprädiktion eingesetzten Planungsalgorithmus abhängig, sodass dieser beinahe beliebig ausgetauscht werden kann.

1.3 Aufbau dieser Arbeit

Die vorliegende Arbeit ist wie folgt gegliedert:

Kapitel 2 gibt einen Überblick über die Grundlagen der in dieser Dissertation abgedeckten Themen. Zunächst werden die Möglichkeiten, das menschliche Fahrverhalten zu modellieren, untersucht und das in dieser Arbeit verwendete Metamodell herausgearbeitet. Dann wird untersucht, wie die Intentionsschätzung von Fahrzeugen in der aktuellen wissenschaftlichen Landschaft gehandhabt wird. Zuletzt wird in diesem Kapitel auf die Möglichkeiten zur Prädiktion sowohl von menschlichem Verhalten allgemein im Straßenverkehr als auch von Fahrzeugtrajektorien im Speziellen eingegangen und aufgeschlüsselt, worin die wesentlichen Unterschiede zwischen gängigen Verfahren bestehen.

Kapitel 3 beschreibt, wie Interaktionen zwischen verschiedenen Fahrzeugen im Kontext dieser Arbeit modelliert werden. Hierfür wird zunächst untersucht, was für Formen von Interaktionen möglich sind und wie solche Interaktionsformen automatisch erkannt werden können. Ein besonderer Fokus liegt hier auf der Verarbeitung von Informationen, die in hochauflösenden Planungskarten für das automatisierte Fahren enthalten sind. Für die in dieser Arbeit betrachteten Interaktionen werden dann ein Graph-basiertes Modell eingeführt und wesentliche Eigenschaften dieser Graphen herausgearbeitet.

Kapitel 4 beschäftigt sich mit dem verfolgten Ansatz zur Trajektorienprädiktion von Fahrzeugen. Ein besonderes Augenmerk liegt hierbei auf der Abbildung von Interaktionen und wie die verschiedenen Möglichkeiten der Interaktionen sich auf die Komplexität der Planung auswirken. Insbesondere werden hierbei die Ergebnisse aus Kapitel 3 aufgegriffen und in Form eines einfachen und effizienten Planungsalgorithmus für die Prädiktion benutzt.

Kapitel 5 befasst sich mit der Intentionsschätzung anderer Verkehrsteilnehmer mithilfe von (nicht-stationären) HMMs. Hierbei befassen sich die einzelnen Teilkapitel mit den jeweiligen Komponenten, aus denen sich ein HMM zusammensetzt. Zunächst wird erklärt, wie ein HMM zur Intentionsschätzung verwendet werden kann und wie das Beobachtungsmodell sowie der Zustandsraum dafür aussehen können. Anschließend wird dieses Modell auf den nicht-stationären Fall erweitert, um sich den dynamischen Änderungen von Verkehrssituationen anpassen zu können.

Kapitel 6 präsentiert die Ergebnisse, die durch die Umsetzung der in den vorherigen Kapiteln beschriebenen Ansätze erzielt werden konnten. Zunächst werden hier die Datensätze vorgestellt, die zur Evaluierung der Ansätze benutzt wurden. Anschließend widmet sich je ein Teilkapitel den Ergebnissen aus den Kapiteln 3-5. Abschließend werden diese Ergebnisse kurz diskutiert.

Kapitel 7 gibt einen abschließenden Überblick über das entstandene Gesamtsystem und führt die wesentlichen in dieser Arbeit gewonnenen Erkenntnisse und Ergebnisse an. Zuletzt gibt dieses Kapitel einen Anstoß für mögliche Ansätze, die auf dieser Arbeit aufbauen könnten.

2 Einordnung in den Stand der Forschung

Dieses Kapitel gibt eine Einführung in die Intentionsschätzung und Verhaltensvorhersage für (hoch-)automatisierte Fahrzeuge. Während beide Themen eng miteinander verknüpft sind, werden sie in der Literatur und im Bereich des hochautomatisierten Fahrens oft separat voneinander behandelt [SHLB18]. Da das zukünftige Verhalten eines Fahrzeuges jedoch maßgeblich von der Intention des Fahrers abhängt, gilt, dass für eine Verhaltensvorhersage von Fahrzeugen zumindest implizit Annahmen über die Intention des Fahrers unvermeidlich sind.

In diesem Kapitel wird zuerst in Abschnitt 2.1 auf die Modellierung von menschlichem Fahrverhalten im Straßenverkehr eingegangen und wie der Zusammenhang zwischen Intentionen und Fahrverhalten modelliert werden kann. Abschnitt 2.2 gibt einen Überblick über die Disziplin der Intentionsschätzung für Fahrzeuge. In Abschnitt 2.3 werden Ansätze zur Verhaltensprädiktion von Fahrzeugen vorgestellt und abschließend werden in Abschnitt 2.4 Grundlagen der Prädiktion von Fahrzeugtrajektorien eingeführt.

2.1 Modellierung von menschlichem Fahrverhalten

Das menschliche Verhalten, ob im Straßenverkehr oder außerhalb, ist geprägt von Entscheidungen. Für jede Aktion, die ein Mensch ausführt, wird eine Entscheidung getroffen, die der Auswahl dieser Aktion und der Ablehnung ihrer Alternativen entspricht. Allerdings zweifelt die Hirnforschung spätestens seit dem sogenannten Libet Experiment [LWF⁺79] in den 1970ern, dass allen Handlungen jederzeit eine bewusste Entscheidung vorausgeht. Dennoch liegen einer Abfolge von Handlungen, wie sie im Straßenverkehr üblicherweise

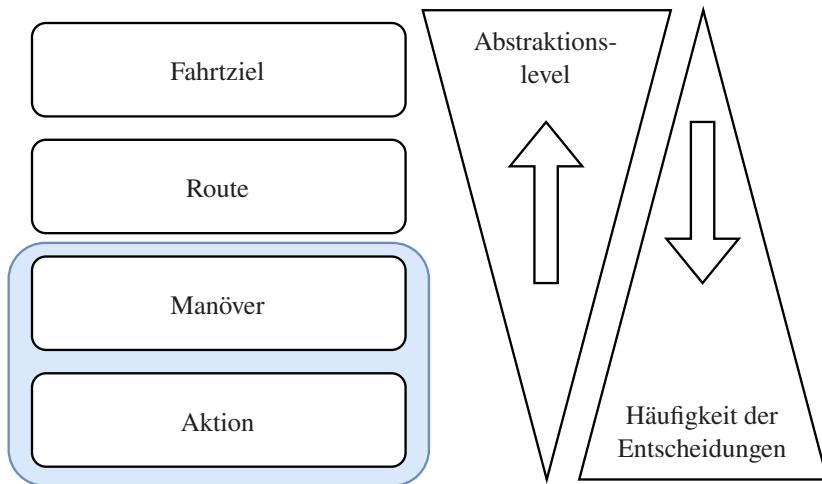


Abbildung 2.1: Die verschiedenen Ebenen, auf denen ein menschlicher Fahrer Entscheidungen trifft. Generell gilt, dass mit absteigendem Grad der Abstraktion die Häufigkeit, mit der Entscheidungen getroffen werden, zunimmt. Blau markiert ist der Fokus dieser Arbeit.

auftreten, eine übergeordnete Zielsetzung des Akteurs, eine Intention, welche die generelle Ausrichtung der Einzelentscheidungen vorgibt, zugrunde. Diese Intentionen und Entscheidungen lassen sich in verschiedene Ebenen unterschiedlicher Granularität der Entscheidungen aufteilen, welche in Abb. 2.1 dargestellt sind. Auf oberster Ebene besteht diese Intention üblicherweise darin, sich mit dem Fahrzeug von einem Startort zu einem Zielort zu bewegen, also die Entscheidung darüber, wohin gefahren werden soll. Diese Entscheidung kann als fest angesehen werden, sobald sie einmal getroffen wurde, da sie sich während der Fahrt hinreichend selten ändert.

Diesem Ziel untergeordnet ist der Plan, wo entlanggefahren werden soll, um diesen Zielort zu erreichen. Die Gesamtheit der Entscheidungen, die auf dieser Ebene für eine Fahrt getroffen werden, bestimmen die Route des Fahrzeugs. Eine Route besteht aus einer geordneten Menge an Wegpunkten zwischen dem Startort und Zielort der Fahrt, welche der Reihe nach durchfahren werden, um den Zielort zu erreichen. Hier treten Entscheidungsänderungen bei längeren Fahrten vereinzelt auf, sollte sich beispielsweise ein Stau auf der Strecke befin-

den. Da der Fokus dieser Arbeit auf einzelnen Verkehrssituationen und nicht auf Langzeitprädiktionen liegt, können auch Entscheidungen und Intentionen auf dieser Ebene als fest angenommen werden. Es ist möglich, diese Entscheidungsebene in weitere Unterebenen aufzuteilen, welche sich darin unterscheiden, wie detailliert und nah beieinander diese Wegpunkte liegen. Hierauf wird jedoch verzichtet, da im Kontext dieser Arbeit das Hauptaugenmerk auf den darunter liegenden Ebenen liegt.

Um einer Route zu folgen, führt ein menschlicher Fahrer mit seinem Fahrzeug eine Reihe von Manövern durch. Als Manöver werden im Kontext dieser Arbeit einzelne Vorgänge, welche zeitlich oder räumlich abgeschlossenes Verhalten beschreiben und einen bestimmten Zweck erfüllen, bezeichnet. Beispiele hierfür sind das Abbiegen, das Einordnen oder ein Überholvorgang. Dem untergeordnet sind nur noch einzelne Aktionen, welche sich auf unterster Ebene durch konkrete Änderungen an der Fahrzeugbewegung manifestieren. Hier handelt es sich beispielsweise um das Lenken, Beschleunigen oder Verzögern.

Während das Fahrtziel und die Route als feste Entschlüsse angenommen werden, sind Manöver und einzelne Aktionen stark kontextabhängig. Die Entscheidungen über durchzuführende Manöver werden spontan basierend auf der aktuellen Verkehrssituation und dem dynamischen Umfeld des Fahrzeugs getroffen. Daher gibt es auf diesen Ebenen häufige Um- und Neuentscheidungen, um sich den dynamischen Gegebenheiten anzupassen. Diese beiden Ebenen sind, worauf sich die Intentionsschätzung und Verhaltensvorhersage in dieser Arbeit hauptsächlich beziehen.

Bei der Betrachtung des Fahrverhaltens eines menschlichen Fahrers sind weder die getroffenen Entscheidungen noch die diesen Entscheidungen übergeordneten Zielsetzungen direkt beobachtbar. Um ein geeignetes Modell für das menschliche Verhalten im Straßenverkehr zu finden, ist es daher notwendig, einen mathematischen Zusammenhang zwischen beobachtbaren Größen und den zu schätzenden Intentionen herzustellen. Brown *et al.* haben 2020 diesbezüglich ein Übersichtspapier veröffentlicht, in welchem sie die verschiedenen Möglichkeiten, wie diese Zusammenhänge in der Literatur behandelt werden, zusammenfassen [BDCK20]. In diesem Papier schlagen sie eine Modellierung von dynamischen Situationen im Straßenverkehr als ein „partiell beobachtbares Stochastisches Spiel“ (Partially Observable Stochastic Game POSG) mit mehreren Agenten und diskreten Zeitschritten vor. Bei einem POSG handelt es sich um eine der allgemeinsten Formen der Modellierung von miteinander




Abbildung 2.2: Ein grafisches Modell, welches den Informationsfluss in einem POSG abbildet. Der physische Zustand x_i jedes Akteurs wirkt sich durch Beobachtungen o_i auf die internen Zustände s_i aller Akteure aus. Der interne Zustand wiederum bestimmt, wie der physische Zustand im nächsten Zeitschritt durch eine Aktion c_i verändert wird. Vgl. Fig. 1. in [BDCK20].

konkurrierenden Agenten mit dynamischen Interaktionen [HB19]. Ähnlich wie ein partiell beobachtbarer Markov Entscheidungsprozess (POMDP) die Unsicherheiten, über die Zustände eines Markov Entscheidungsprozesses (MDP) für einzelne Agenten, modellieren kann, erlaubt es ein POSG zusätzlich, die Unsicherheiten die sich durch unterschiedliche Beobachtungen der einzelnen Agenten, sowie die unterschiedlichen Belief-Zustände bei mehreren Agenten ergeben, abzubilden [EMGST04].

Optimale Lösungen für die Aktionswahl aller Akteure in einem POSG zu finden, ist ein komplexes und für allgemeine POSGs aktuell ungelöstes Problem. Stattdessen werden üblicherweise Näherungslösungen für Spezialfälle eines POSGs unter bestimmten Annahmen betrachtet. In dieser Arbeit wird wiederholt Bezug auf den Informationsfluss in POSGs genommen werden, um zu veranschaulichen, wie sich die hier vorgestellten Konzepte in dieses allgemeine Modell abbilden lassen. Denn während keine vollständige Modellierung aller Aspekte eines POSG im Kontext dieser Arbeit umgesetzt wird, ist diese gut geeignet, um den Informationsfluss zwischen mehreren Fahrzeugen in natürlichen Verkehrssituationen auf ähnliche Art und Weise darzustellen, wie sie auch in dieser Arbeit angenommen wird. Um dies zu illustrieren, ist eine grafische Modellierung des Informationsflusses in einem POSG in Abb. 2.2 abgebildet. In jedem Zeitschritt hat jeder Agent bzw. Autofahrer einen internen Zustand s , welcher alle unbeobachtbaren Aspekte beinhaltet, die sich auf die Entschei-

dung über die gewählte Aktion c auswirken. Insbesondere ist die Intention, wie sie zuvor eingeführt wurde, Teil dieses internen Zustands aller Agenten. Als Aktionen werden alle Handlungen bezeichnet, die sich auf den physischen Zustand x eines Akteurs auswirken. Die Menge der möglichen Aktionen ist weitgehend deckungsgleich mit den Aktionen, die auf der untersten Abstraktionsebene in Abb. 2.1 getroffen werden. Der physische Zustand eines Akteurs wiederum kann von anderen Akteuren beobachtet werden. Eine Besonderheit bei allgemeinen POSGs ist hier, dass die Beobachtungsfunktionen, welche die Beobachtungen o über die physischen Zustände anderer Fahrzeuge liefern, nicht für alle Akteure identisch sein müssen. Es ist möglich, dass ein Akteur Informationen über die physischen Zustände anderer Akteure erhält, die nicht allen Akteuren ebenfalls zur Verfügung stehen. Dieser Aspekt wird im Kontext dieser Arbeit teilweise über den Abhängigkeitsgraphen in Kapitel 3 abgebildet, welcher den Informationsfluss zwischen Fahrzeugen in dem Modell dieser Arbeit vorgibt. Der letzte Part des Informationsflusses beschreibt, wie sich Beobachtungen auf die internen Zustände der einzelnen Akteure auswirken. Dieser Informationskreislauf von internem Zustand über Aktionen, welche den physischen Zustand beeinflussen, der sich über Beobachtungen wieder auf die internen Zustände auswirkt, passiert in einem (zeitdiskreten) POSG für jeden Zeitschritt einmal.

2.2 Intentionsschätzung von Fahrzeugen

Obwohl die Vorhersage des Verhaltens anderer Fahrzeuge für die Planung des eigenen Verhaltens oft das übergeordnete Ziel der Intentionsschätzung ist, gibt es Fälle, in denen die Schätzung der Intention selbst von Interesse ist. In vielen Situationen reicht es für die Verhaltensplanung beispielsweise bereits, abschätzen zu können, ob ein anderes Fahrzeug die Intention hat, die eigene Fahrspur zu queren, ohne die konkreten Verhaltensweisen dieses Fahrzeugs explizit vorherzusagen. In diesen Fällen kann eine Intentionsschätzung einer Verhaltensvorhersage vorgeschaltet werden, um zu entscheiden, welche Fahrzeuge präzisiert werden sollten und welche nicht für die Situation relevant sind.

Die Intentionsschätzung selbst kann aus mehreren Blickwinkeln betrachtet werden. Im Kontext eines POSGs entspricht sie der Ermittlung der verborge-

nen Zustände s der einzelnen Akteure. Als externer Beobachter kann dies nur durch die Untersuchung der nach außen verfügbaren Informationen geschehen. Kann der Betrachter selbst Aktionen auswählen, beispielsweise als Teil eines Softwaremoduls für selbstfahrende Fahrzeuge, so ist der Beobachter selbst als Mitspieler dieses POSGs anzusehen. In diesem Fall modelliert die Schätzung der Intention anderer Fahrzeuge den Informationsfluss der eigenen Beobachtungsfunktion in den eigenen (internen) Zustand. Ist dies der Fall, handelt es sich um eine asymmetrische Modellierung, da für einen Spieler, den Beobachter selbst, keine Unsicherheit über den internen Zustand besteht. Hier wird häufig nur nach der optimalen Handlungsweise für sich selbst gesucht und die Intentionen der anderen Verkehrsteilnehmer sind Einflussfaktoren bei dieser Problemstellung. Ist dies der Fall, so werden die Intentionen der anderen Fahrzeuge oft als Unsicherheiten und unter vereinfachenden Annahmen im Kontext eines POMDP betrachtet und das Problem als solches modelliert.

Ob der Betrachter selbst Teil des POSG ist oder unabhängig die Situation von außen betrachtet, in beiden Fällen muss über limitierte Informationen, welche über irgendeine Form von Beobachtungsfunktion geliefert wird, auf die internen Zustände einer Menge von Fahrzeugen geschlossen werden. Ein gängiger Ansatz hierbei ist, dieses Problem als Klassifizierungsproblem anzusehen und entsprechend Klassifizierungsmethoden anzuwenden. Diese sind beispielsweise Support Vektor Maschinen (SVMs) [ADSH11, KWE16, YDW23], Random Forests (RFs) [BLSIG17], Künstliche Neuronale Netze (KNNs) [PWK17, XWC⁺18, IQP⁺19, ZSF⁺21] oder probabilistische, graphbasierte Ansätze, wie Bayes'sche Netze (BN) [LLIG11, Son21] oder Hidden Markov Modelle (HMMs) [AHKK17], für welche der hier gewählte Ansatz in Kapitel 5 ebenfalls ein Beispiel ist. Diese Ansätze arbeiten üblicherweise auf einer im Vorhinein berechneten endlichen Menge von möglichen Klassifizierungsergebnissen, welche den zuvor vorgestellten Manövern entsprechen [SHLB18]. Es gibt allerdings auch Versuche, diese durch unüberwachtes Lernen zu bestimmen [GJ19]. Oft wird hier zwischen Ansätzen für unterschiedliche Manöverklassen unterschieden. Insbesondere werden üblicherweise zwischen innerstädtischen Kreuzungssituationen, in welchen Intentionen auf Routing-Ebene im Vordergrund stehen, und Situationen auf Landstraßen und Autobahnen unterschieden, bei denen hauptsächlich Fahrstreifenwechsel- und Überholmanöver auftreten. Des Weiteren betrachten diese Ansätze meistens nur Einzelfahrzeuge, ohne deren Relation zu anderen zu betrachten. Die explizite Modellierung dieser Relationen, wie sie auch im Kontext dieser Arbeit

geschieht, fand in den letzten Jahren insbesondere in der Domäne der KNNs Einzug, die auf Datensätzen mit mehreren Fahrzeugen trainiert wurden und so die Inter-Fahrzeug-Relationen implizit aus den Daten lernen. Auch explizite Abhängigkeitsmodellierungen für KNNs sind möglich, wie sie beispielsweise in der Form von Graphen-basierten Neuronalen Netzen in [Wir23] umgesetzt wurde.

2.3 Prädiktion von menschlichem Fahrverhalten im Straßenverkehr

Das Thema der Prädiktion von beobachteten Fahrzeugen im Straßenverkehr ist ein in der Literatur bereits umfassend und aus vielen Perspektiven betrachtetes Thema. Dennoch ist es nach wie vor Gegenstand von intensiven Forschungsanstrengungen. Dies liegt zum einen daran, dass es unmöglich ist, immer perfekte Vorhersagen auf Basis von unsicheren Informationen zu treffen, und somit immer Potential und damit auch Forschungsbedarf für Verbesserungen existiert. Zum anderen liegt es auch an der Kritikalität der Information, die in einem Prädiktionsalgorithmus geschätzt wird. Denn würde ein Algorithmus vorliegen, der das Verhalten des gesamten dynamischen Umfelds eines Fahrzeugs zuverlässig vorhersagt, könnten keine unerwarteten Situationen im Straßenverkehr mehr auftreten. Somit könnte das hochautomatisierte Fahren mit einem in der Realität unerreichbaren Grad an Sicherheit für alle Verkehrsteilnehmer realisiert werden.

Bei der zuvor eingeführten Betrachtung der Verhaltensmodellierung menschlicher Akteure als POSG steht im Fokus der Fragestellung der Verhaltensvorhersage die Aufgabe, zu einem Zeitpunkt t Aussagen über die physischen Zustände der einzelnen Akteure x_i zu einem n Zeitschritte in der Zukunft liegenden Zeitpunkt $t + n \cdot \Delta t$ zu treffen. Ansätze hierfür werden umfangreich in vergangenen Übersichtsschriften von Sivaraman *et al.* [ST13], Lefèvre *et al.* [LVL14], Mozaffari *et al.* [MAJD⁺20] und Rudenko *et al.* [RPH⁺20] erläutert. Die bestehenden Ansätze lassen sich hierbei nach unterschiedlichen Gesichtspunkten kategorisieren. Ein Überblick über die häufigsten Modellierungsentscheidungen ist in Abb. 2.3 gegeben. Eine weitere Kategorisierung, die insbesondere im Hinblick auf die Entwicklungen von Algorithmik für das

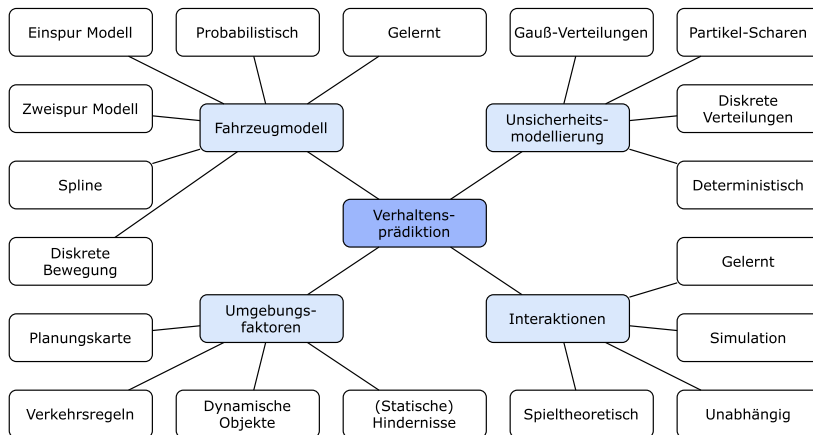


Abbildung 2.3: Eine Übersicht über häufige Modellierungsentscheidungen bei der Realisierung von Fahrzeugprädiktionsalgorithmen.

hochautomatisierte Fahren notwendig ist, ist die Unterscheidung zwischen gelernten und klassischen Ansätzen zur Verhaltensprädiktion.

Insbesondere in den letzten Jahren wurde eine Vielzahl an Ansätzen für die Vorhersage von Fahrzeugverhalten mittels künstlicher neuronaler Netze (KNNs) und sogenannter, oft mit KNNs gleichgesetzter *Künstlicher Intelligenz* veröffentlicht. Während diese Ansätze äußerst vielversprechende Ergebnisse zeigen, haben sie das Problem, dass sie aus systemtheoretischer Sicht weitgehend als Black Box anzusehen sind. Zwar lassen sich statistische Aussagen über die Güte der Vorhersagen dieser Ansätze treffen, jedoch lässt sich nicht prüfen, ob diese Ansätze reale Zusammenhänge und Ursachen für menschliches Verhalten verstehen und entsprechend auch in Situationen, die nicht in den Datensätzen vorkamen, korrekte Vorhersagen treffen können.

Dem entgegen stehen die sogenannten klassischen Ansätze. Bei diesen wird versucht, vereinfachende Annahmen über die hochkomplexe Aufgabe der Fahrzeugprädiktion zu treffen, um basierend auf diesen Annahmen bekannte Zusammenhänge und Einflüsse auf menschliches Verhalten explizit zu modellieren. Diese Form von Ansätzen hat den Vorteil, dass die Funktionsweise des Modells transparent und in der Regel menschlich interpretierbar ist. Somit

können Metaaussagen über das Modell getroffen werden, wie zum Beispiel, ob eine gegebene Situation den Modellannahmen entspricht und somit auch, ob in dieser Situation sinnvolle Aussagen vom Modell getroffen werden können. Die Nachteile sind, dass durch die explizite Modellierung in der Regel nur ein kleiner Teilbereich aller möglichen Verkehrssituationen abgedeckt wird und diese Ansätze somit im Vergleich zu KNN-basierten Ansätzen, die in der Regel weniger spezialisiert sind, schlechtere Ergebnisse auf großen Datensätzen des natürlichen Straßenverkehrs erzielen.

Da eine umfassende Betrachtung beider Arten von Ansätzen den Rahmen dieser Arbeit sprengen würde und der hier vorgestellte Ansatz in die zweite Kategorie fällt, wird im Kontext dieser Arbeit hauptsächlich auf die zweite Kategorie von Ansätzen – den klassischen Ansätzen – detaillierter eingegangen. Für Interessenten an Ansätzen der ersten Kategorie wird auf die Veröffentlichungen [RPH⁺20, VHS⁺22, MAJD⁺20, Wir23] verwiesen, welche einen guten Überblick über diesbezügliche Entwicklungen in den letzten Jahren geben.

2.4 Trajektorienprädiktion für Fahrzeuge

Die häufigsten Formen der Verhaltensvorhersage von Fahrzeugen sind die Pfad- und Trajektorienprädiktionen. Ein Pfad bezeichnet im Kontext dieser Arbeit eine geordnete Menge von Wegpunkten zwischen einem Start- und einem Zielpunkt. Eine Trajektorie auf der anderen Seite gibt zusätzlich temporale Informationen darüber, zu welchem Zeitpunkt jeder dieser Wegpunkte durchfahren wird. Entsprechend wird im Kontext dieser Arbeit der Begriff Trajektorie als eine zeitlich geordnete Abfolge von Wegpunkten verstanden, die ein Fahrzeug der Reihe nach durchfährt. Von einem Pfad wird gesprochen, wenn lediglich eine räumliche Sortierung dieser Punkte vorliegt.

Erwähnenswert ist, dass bei reinen Pfad- oder Trajektorienprädiktionen in aller Regel die räumliche Ausdehnung der betrachteten Fahrzeuge vernachlässigt wird und sich die Position der Fahrzeuge somit auf einzelne Punkte reduziert. Dies kann in der Praxis offensichtlich zu Problemen führen, falls sehr genaues Manövrieren notwendig ist. Da in den meisten Anwendungsfällen jedoch Annäherungen zwischen Fahrzeugen auf wenige Zentimeter unerwünscht sind, ist diese Punktannahme häufig ausreichend, wenn großzügige Abstände zu den prädierten Positionen gehalten werden.




Abbildung 2.4: Ein Beispiel für Pfad- und Trajektorienprädiktion. Damit das grüne Fahrzeug eine einfache Fahrt entlang der eigenen Fahrbahn planen kann, muss die Trajektorie des blauen Fahrzeugs, jedoch nur der Pfad des roten Fahrzeugs prädiziert werden.

Ansätze zur Pfadprädiktion sind in der Praxis weitgehend mit Intentionsschätzungen auf den Ebenen von Routing und Manöver gleichzusetzen. Sowohl die Entscheidung über die Route – wo soll entlanggefahren werden – als auch die Entscheidung über das Manöver – z.B. ein Überholvorgang – werden durch den Fahrzeugpfad abgebildet. Diese Form der Prädiktion ist, wie in Abschnitt 2.2 bereits angedeutet, ausreichend, um Fahrzeuge zu identifizieren, mit denen andere Fahrzeuge interagieren müssen. Für Fahrzeuge, deren prädizierter Pfad innerhalb des eigenen Planungshorizonts die eigene geplante Fahrbahn überschneidet, ist es notwendig, zusätzlich zu dem Pfad temporale Informationen zum Beispiel in Form einer Trajektorie zu erhalten.

Dies ist in Abb. 2.4 illustriert. Für das grüne Fahrzeug ist eine Intentionsschätzung, dass das rote Fahrzeug nicht in den nächsten Sekunden den Fahrstreifen wechselt, ausreichend, um die eigene Fahrt entlang der aktuellen Fahrbahn zu planen. Somit ist für dieses Fahrzeug eine Intentionsschätzung oder eine Pfadprädiktion ausreichend. Über das blaue Fahrzeug hingegen muss zusätzlich bekannt sein, dass es sich zu Beginn am Anfang des Pfades und zum Ende des Prädiktionshorizonts am Ende des Pfades befinden wird. Andernfalls müsste das grüne Fahrzeug stark verzögern, um zu verhindern, innerhalb des Prädiktionshorizonts auf den Pfad des blauen Fahrzeugs zu fahren. Somit muss für das blaue Fahrzeug eine Trajektorienprädiktion durchgeführt werden. Im Verlaufe dieser Arbeit wird ein Ansatz vorgestellt, die einzelnen Optionen, die

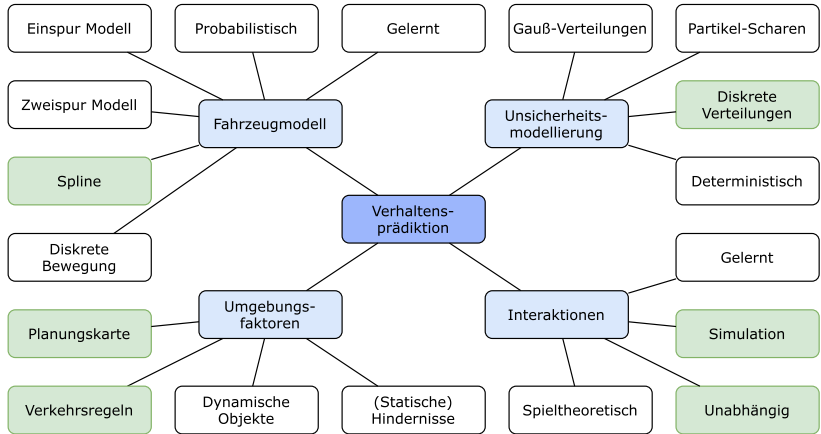


Abbildung 2.5: Erneut die Übersicht über mögliche Aspekte der Verhaltensprädiktion, dieses Mal mit Hervorhebung der Aspekte, die im Kontext dieser Arbeit behandelt werden, in grün.

ein Fahrzeug durchfahren kann, zu bewerten und basierend auf diesen Bewertungen strategische Entscheidungen darüber zu treffen, wie die Prädiktion der einzelnen Fahrzeuge durchgeführt werden sollte.

Umfangreiche Literaturübersichten über Ansätze zur Trajektorienprädiktion gab es bereits mehrfach in den letzten Jahren. Neben den Übersichten von Lefèvre *et al.* [LVL14], Mozaffari *et al.* [MAJD⁺20] und Rudenko *et al.*, welche sowohl Intentionsschätzung als auch Trajektorienprädiktionsansätze beinhalten, wurde außerdem 2022 eine Literaturübersicht speziell über Ansätze zur Trajektorienprädiktion von Huang *et al.* veröffentlicht [HDY⁺22]. Auch hier wird als wichtiger Unterschied herausgearbeitet, in welcher Form die Ergebnisse der Prädiktion ausgegeben werden. Neben der Intention (bzw. dem Pfad) und einzelner Trajektorien werden hier außerdem multimodale Ausgaben, das bedeutet Ausgaben, die mehr als eine einzige Trajektorie pro Fahrzeug ausgeben, angeführt. Die neueste dem Autor bekannte Übersichtsschrift wurde 2024 von Galvão und Huda veröffentlicht [GH24] und befasst sich insbesondere mit dem Zusammenhang zwischen Intentionen und Verhalten von Verkehrsteilnehmern.

Um die Arbeit, die hier vorgestellt wird, in den Kontext dieser verwandten Ansätze zu platzieren, zeigt Abb. 2.5 die Aspekte auf, in dieser Arbeit ausgewählt wurden. Das Fahrzeugmodell ist streng genommen nicht fest vorgegeben. Es hängt davon ab, wie der Planungsansatz, der für die Simulation der nächsten Zeitschritte verwendet wird, umgesetzt wird. Das Fahrzeugmodell, welches im Kontext der Evaluation verwendet wurde, ist ein für unsere Zwecke angepasstes Modell, welches sich entlang der als Spline repräsentierten Mittellinie des Fahrstreifens bewegt. Dies wird in Kapitel 4 genauer erläutert. Die Unsicherheitsmodellierung wird insbesondere in Kapitel 5 herausgearbeitet. Im Kontext dieser Arbeit wird von einer endlichen, diskreten Menge an möglichen Fahrzeugintentionen ausgegangen, über die eine (diskrete) Wahrscheinlichkeitsverteilung in jedem Zeitschritt geschätzt wird. Die Umgebungsinformationen, welche hier benutzt werden, leiten sich hauptsächlich aus den Informationen über andere Verkehrsteilnehmer sowie der Planungskarte ab. In dem Kartenmodell, welches hier benutzt wird, sind ebenfalls die in der jeweiligen Situation geltenden Verkehrsregeln hinterlegt. Dies ist näher in Kapitel 3 dargelegt. Die Modellierung der Interaktionen zwischen Fahrzeugen basiert auf einer Reihe von Annahmen, welche in Kapitel 3 aufgeführt sind. Fahrzeuge werden in dieser Modellierung in eine hierarchische Struktur gebracht, in welcher einige Fahrzeuge unabhängig von den anderen vorhergesagt werden können, während das Verhalten anderer durch eine Simulation vorhergesagt wird, welche Abhängigkeiten zu anderen Fahrzeugen berücksichtigt. Dieses Vorgehen wird detailliert in Kapitel 3 und 4 vorgestellt.

3 Modellierung von Fahrzeuginteraktionen

In diesem Kapitel wird ein Ansatz zur Modellierung von Abhängigkeiten zwischen den Verhalten unterschiedlicher Fahrzeuge sowie der daraus entstehenden Interaktionen vorgestellt. Eine zentrale Rolle spielen hierbei die Planungskarte und die geltenden Verkehrsregeln, welche gemeinsam die Rahmenbedingungen bilden und somit die notwendigen Informationen über die erlaubten Verhaltensweisen der einzelnen Verkehrsteilnehmer liefern.

Das Kapitel gliedert sich hierbei wie folgt. Zunächst wird in Abschnitt 3.1 erklärt, welchen Teil des Gesamtmodells dieses Kapitel abdeckt und welche Formen von Interaktionen möglich sind. Anschließend wird in Abschnitt 3.2 unter anderem anhand eines Beispiels das für diese Arbeit zentrale Konzept der kritischen Bereiche eingeführt. Wie diese automatisiert aus einer Karte gewonnen werden können und welche Rolle die geltenden Verkehrsregeln dabei spielen, wird jeweils in Abschnitt 3.3 und Abschnitt 3.4 erläutert. Abschnitte 3.5 und 3.6 erklären den für die Modellierung essenziellen Abhängigkeitsgraphen und wie dessen Topologie für die Verwendung in den Algorithmen der folgenden Kapitel analysiert werden kann. Abschließend beschreibt Abschnitt 3.7, wie Abhängigkeiten zwischen Fahrzeugen in dieser Arbeit quantisiert werden.

3.1 Einführung in Interaktionen

Für eine realistische Verhaltensprädiktion von Fahrzeugen ist eine Beachtung der Interaktionen zwischen ebendiesen notwendig. Als Interaktion im Kontext dieser Arbeit werden alle Situationen bezeichnet, in denen das Verhalten eines Fahrzeugs sich an das Verhalten eines anderen Fahrzeuges anpassen muss, um sein eigenes Ziel zu erreichen. Diese finden üblicherweise in gegenseitiger

Wechselwirkung statt, da sich Fahrzeuge gegenseitig beeinflussen, wenn sie sich in direkter Nähe zueinander im fließenden Straßenverkehr befinden.




Abbildung 3.1: Abhängigkeitsmodellierung im Kontext eines POSGs. Der in grün hervorgehobene Datenfluss, welcher bestimmt, wie die physischen Zustände x_n andere Fahrzeuge beeinflussen, basiert auf den Abhängigkeiten zwischen Fahrzeugen.

Im Kontext des zuvor in Abschnitt 2.1 eingeführten Informationsflusses in der Modellierung als POSG beschreibt die Abhängigkeitsmodellierung, zwischen welchen Fahrzeugen Informationen ausgetauscht werden. Wie in Abb. 3.1 zu sehen, basieren die Beobachtungen o_n , welche jedes einzelne Fahrzeug n über seine Umwelt macht und wodurch der interne Zustand s_n des Fahrzeugs beeinflusst wird, auf den physischen Zuständen $X = \{x_1, x_2, \dots\}$ aller Fahrzeuge. Da in natürlichen Verkehrssituationen üblicherweise jedoch nicht jedes Fahrzeug das Verhalten jedes anderen Fahrzeugs beeinflusst, wird in diesem Kapitel untersucht, wie sich die Menge von Abhängigkeiten auf eine möglichst kleine Teilmenge der Fahrzeuge reduzieren lässt. Offensichtlich ist hierbei essenziell, dass dabei dennoch alle für das Verhalten eines Fahrzeugs relevanten Informationen dem Beobachtungsmodell eines Fahrzeugs zur Verfügung stehen. Um dies zu bewerkstelligen, wird zunächst untersucht, welche Formen von Interaktionen zwischen Fahrzeugen existieren und welche insbesondere in urbanen Szenarien relevant sind. Anschließend werden vereinfachende Annahmen über den Verlauf dieser Interaktionen aufgestellt, um basierend auf diesen ein geeignetes Modell der Abhängigkeiten aufzustellen.

Generell lassen sich Interaktionen zwischen Fahrzeugen im Straßenverkehr in zwei Kategorien unterteilen. Die Kategorie der ortsgebundenen Interaktionen beschreibt hierbei die Gesamtheit aller Interaktionen zwischen Fahrzeugen, die

im Wesentlichen durch die Straßentopologie herbeigeführt werden. Beispiele hierfür sind die Überschneidung oder Zusammenführung von Fahrspuren, die es erfordern, dass Fahrzeuge ihr Verhalten an diesen Stellen mit anderen Verkehrsteilnehmern koordinieren. Dem gegenübergestellt sind kontinuierliche Interaktionen, welche sich über einen längeren örtlichen und zeitlichen Rahmen erstrecken können. Diese Interaktionsform tritt beispielsweise bei einer Folgefahrt auf, bei welcher das hintere Fahrzeug die eigene Geschwindigkeit an das Fahrverhalten des vorausfahrenden Fahrzeuges anpassen muss. Auch Spurwechsel und Überholvorgänge, bei denen die Fahrzeuge auf der Nebenspur berücksichtigt werden müssen, fallen in diese Kategorie. Bei den im Fokus dieser Arbeit liegenden Kreuzungsszenarien treten überwiegend ortsgebundene Interaktionen sowie Folgefahrten auf, während verschiedene Formen von kontinuierlichen Interaktionen beispielsweise in Autobahnszenarien verstärkt auftreten. Das Hauptaugenmerk dieses Kapitels liegt insbesondere auf der Modellierung von Interaktionsformen, wie sie in (urbanen) Kreuzungssituationen häufig sind.

3.2 Interaktions- und Entscheidungspunkte

Ortsgebundene Interaktionen treten, wie der Name schon sagt, nur an bestimmten Orten, welche durch die Straßentopologie vorgegeben sind, auf. In allen Bereichen, in denen sich mehrere Fahrstreifen flächenmäßig überlappen und diese nicht demselben Fahrstreifen entspringen, ist eine Form von Interaktion zwischen den Fahrzeugen auf den unterschiedlichen Spuren notwendig, um realistisches Fahrverhalten erfolgreich abzubilden. Analog zu manchen Ansätzen der Trajektorienplanung (z.B. [tBP96]) wird der sich überlappende Bereich mehrerer Fahrbahnen hier als kritischer Bereich bezeichnet. Obwohl diese Bereiche von mehreren Fahrspuren aus erreicht werden können, darf zu jedem Zeitpunkt dennoch nur ein Fahrzeug einen kritischen Bereich passieren, da ansonsten eine kritische Situation zustande kommen kann. Ein Beispiel für kritische Bereiche ist in Abb. 3.2 dargestellt. Fahrspur A kreuzt Fahrspur C und wird anschließend mit Fahrspur D zu Fahrspur B zusammengeführt. Es entstehen zwei kritische Bereiche, die jeweils nicht zeitgleich von Fahrzeugen von A und C bzw. A und D befahren werden dürfen. Im Folgenden werden zur Vereinfachung der Darstellungen die kritischen Bereiche auf die rot umkreisten Interaktionspunkte, die Schnittpunkte der Mittellinien der betroffenen




Abbildung 3.2: Zwei kritische Bereiche, die durch die Überlagerung der Fahrspuren A, C und D entstehen. Die kritischen Bereiche sind grün markiert, in Rot werden jeweils die Projektionen der Bereiche auf die Mittellinien und die Interaktionspunkte markiert.

Fahrspuren, reduziert. Falls keine Überschneidung der Mittellinien erfolgt, so wird der Interaktionspunkt auf den geometrischen Schwerpunkt des kritischen Bereichs gesetzt. Tatsächlich umfassen die entsprechenden Bereiche in der internen Repräsentation allerdings den gesamten rot gestrichelten Bereich der jeweiligen Fahrbahnen.

Neben kritischen Bereichen, beziehungsweise Interaktionspunkten, an denen sich die Interaktionen zwischen Fahrzeugen auf unterschiedlichen Fahrbahnen abspielt, lassen sich aus der Straßentopologie ebenfalls Entscheidungspunkte definieren, an welchen entschieden wird, mit welchen Fahrzeugen zukünftige Interaktionen auftreten werden. Konkret bedeutet dies, dass als Entscheidungspunkte in dieser Arbeit alle Bereiche bezeichnet werden, in welchen sich ein Fahrer zwischen mehreren Möglichkeiten entscheiden muss, seine Route fortzusetzen. Im Kontext der zuvor in Abschnitt 2.1 eingeführten Entscheidungsebenen sind die hier getroffenen Entscheidungen auf Ebene des Routings und somit als weitgehend bereits im Vorhinein getroffene, dem Beobachter aber unbekannte Entscheidungen einzuordnen. Dies ist beispielsweise an jeder Weggabelung und Abbiegemöglichkeit der Fall. Da sich an diesen Punkten entscheidet, mit welchen anderen Verkehrsteilnehmern das entsprechende Fahrzeug in der Zukunft interagieren wird, sind diese Punkte für die Modellierung von Fahrzeuginteraktionen sehr wichtig. Abb. 3.3 illustriert beide vorgestellten Konzepte. Welche ortsgebundenen Interaktionen zwischen Fahr-




Abbildung 3.3: Ein Beispiel für kritische Interaktionspunkte (rot) und Entscheidungspunkte (grün) basierend auf einem echten Kreisverkehr aus dem INTERACTION-Datensatz [ZSW⁺19]. Beim gelben Kreis wurden ein Interaktions- und Entscheidungspunkt zu einem einzigen kritischen Bereich zusammengeführt.

zeugen in dieser Straßensituation auftreten werden, entscheidet sich jeweils an den markierten Interaktions- bzw. Entscheidungspunkten.

Das hier abgebildete Szenario eines Kreisverkehrs wird in den folgenden Kapiteln wiederholt auftreten und mehrfach als Standardbeispiel zur Illustration der vorgestellten Konzepte dienen. Hierfür gibt es mehrere Gründe. Zum einen handelt es sich anders als beispielsweise in Abb. 3.2 nicht um ein konstruiertes Beispiel, sondern um einen Ausschnitt, wie er im INTERACTION Datensatz aufgenommen wurde. Zweitens tauchen in diesem Szenario sowohl Interaktionen als auch Entscheidungen an mehreren Punkten und in mehreren Formen auf, wodurch auch komplexere Verkehrssituationen möglich sind. Dennoch ist die eigentliche Straßentopologie hinreichend einfach, um die hier vorgestellten Konzepte in übersichtlicher Form illustrieren zu können. In Anhang A ist in Abb. A.1a ein Luftbild der echten Verkehrssituation gegeben, aus der die schematische Darstellung hier extrahiert wurde.




Abbildung 3.4: Beispielhafter Aufbau einer Planungskarte im Lanelet2-Format. Der gesamte befahrbare Bereich ist unterteilt in mehrere Flächen - den sogenannten Lanelets $\tilde{A} - \tilde{H}$, über welche separat Metainformationen, wie Verkehrsregeln und deren Bezüge, abgespeichert sind. Bildquelle: [PPJ⁺18].

3.3 Verarbeitung von Karteninformationen

Es wird im Kontext dieser Arbeit davon ausgegangen, dass eine hochdetaillierte Planungskarte der Bereiche, in welchen prädictiert werden soll, vorliegt. In dieser Karte sind alle für die Planung oder Prädiktion von Fahrzeugen relevanten statischen Informationen, wie die Straßentopologie, Geschwindigkeitsbegrenzungen oder geltende Vorfahrtsregeln hinterlegt. Ein für diesen Zweck geeignetes Kartenformat ist mit dem Lanelet2-Framework [PPJ⁺18] gegeben, welches 2019 von Poggenhans *et al.* veröffentlicht wurde. Als geistiger Nachfolger des 2013 von Bender *et al.* veröffentlichten liblanelet Frameworks [BZS14] unterteilt es Straßen und Fahrstreifen in kurze (Fahrstreifen-)Abschnitte, den für beide Veröffentlichungen namensgebenden Lanelets. Die Unterteilung erfolgt hierbei so, dass innerhalb eines Lanelets jeweils dieselben Verkehrsregeln, wie z.B. dieselbe Geschwindigkeitsbegrenzung gelten. Die Relationen der Lanelets untereinander wiederum bestimmen die Topologie, die für Routenplanung und Prädiktion verwendet werden kann. Konkateniert man mehrere miteinander verbundenen Lanelets, ergibt sich ein befahrbarer Bereich der Karte, welchem Fahrzeuge folgen können. In Abb. 3.4 ist dies beispielhaft illustriert. Die Relationen, welche bestimmen, welche Lanelets miteinander verbunden sind,

werden separat von den physischen Eigenschaften der Lanelets in einem sogenannten Routing Graphen abgespeichert. Da befahrbare Bereiche im Sinne der Graphen-Theorie immer entlang von Pfaden des Routing Graphen führen, wird hier im Folgenden von Fahrzeugpfaden geschrieben. Bestimmt man für ein Fahrzeug alle Lanelets, auf denen sich das Fahrzeug befindet, so kann man durch Folgen der Relationen im Routing Graphen alle möglichen Fahrzeugpfade, denen das Fahrzeug folgen kann, ohne gegen die Verkehrsregeln zu verstoßen, herleiten.

Da Interaktions- und Entscheidungspunkte durch die Topologie der Fahrstreifen vorgegeben sind, ist es möglich, diese bereits im Vorhinein zu berechnen und als ergänzende Informationen zu der Planungskarte abzuspeichern. Hierzu wird über alle Lanelets der zu befahrende Karte iteriert, um alle Interaktions- sowie Entscheidungspunkte zu suchen. Es werden Entscheidungspunkte überall dort initialisiert, wo ein Lanelet mehrere mögliche Folge-Lanelets aufweist. Dies ist genau dann der Fall, wenn ein Fahrzeug mehrere Möglichkeiten hat, seine Route fortzusetzen, und entsprechend eine Entscheidung notwendig ist. Dem Fahrzeug sind somit mehrere mögliche Fahrzeugpfade zugeordnet.




Abbildung 3.5: Der rechte Konfliktbereich aus Abb. 3.2 inklusive der für die Berechnung relevanten Punkte s_A , s_D , e_A , e_D jeweils in Blau und den Intervallen I_A und I_D jeweils in Rot.

Interaktionspunkte wiederum werden überall dort initialisiert, wo mehrere Lanelets räumlich übereinanderliegen, die nicht dasselbe Vorgängerlanelet haben und somit Teil eines Entscheidungspunktes wären. Das Ergebnis beider Analysen ist jeweils eine Menge von Lanelets \mathcal{L} , die untereinander in einer Konflikt/Entscheidungs-Relation stehen, sowie die entsprechenden Teilbereiche des Lanelets, in denen sich diese Relation manifestiert. Um die Datenmenge

und Komplexität der folgenden Berechnungen zu reduzieren, wird jedoch nicht mit den Polygonen, welche die Bereiche aufspannen, sondern jeweils nur mit den Intervallen, welche durch die Projektion des Polygons auf die Mittellinie des entsprechenden Lanelets entstehen, gearbeitet. Eine Illustration dieses Konzepts ist in Abb. 3.5 dargestellt. Der rechte Konfliktbereich $\mathcal{K}_r = \{\mathcal{L}_r, \mathcal{I}_r\}$ in dieser Abbildung wird in diesem Fall repräsentiert durch die Menge der beteiligten Lanelets $\mathcal{L}_r = \{A, D\}$ sowie der Menge der entsprechenden Intervalle $\mathcal{I}_r = \{I_A, I_D\}$ entlang der jeweiligen Mittellinien. Hierbei repräsentiert I_X jeweils die Menge aller Punkte, die auf der Mittellinie des Lanelets X innerhalb des Intervalls zwischen den Start- und Endpunkten s_X, e_X liegen. Der Index r steht hier für „rechts“, im Folgenden wird stattdessen üblicherweise eine allgemeinere Indizierung verwendet.

Da in Karten von realen Verkehrssituationen häufig komplexe Überlappungen und Zusammenführungen mehrerer Fahrbahnen in kurzen Abständen zueinander auftreten, wird als nächster Schritt die Anzahl der betrachteten Bereiche durch ein Clustering-Verfahren reduziert. Hierbei werden alle Interaktions- und Entscheidungspunkte zusammengeführt, die nahe beieinander liegen und sich auf dieselben Fahrbahnen beziehen. Letzterer Punkt ist wichtig, um zum Beispiel zu verhindern, dass ein Konfliktbereich mit einem Konfliktbereich der Gegenfahrbahn zusammengefasst wird, obwohl keine Interaktion zwischen den Fahrzeugen auf diesen Bahnen vorkommen sollte. Konkret heißt das, dass für alle Interaktionsbereiche $\mathcal{K}_i = \{\mathcal{L}_i, \mathcal{I}_i\}, \mathcal{K}_j = \{\mathcal{L}_j, \mathcal{I}_j\}$, die zu einem Cluster C zusammengefügt werden, gegeben einer maximalen Distanz d_{\max} Folgendes gelten muss:

$$\exists L(L \in \mathcal{L}_i \wedge L \in \mathcal{L}_j) \quad \forall \mathcal{K}_i, \mathcal{K}_j \in C$$

und

$$\exists I_i \in \mathcal{I}_i, I_j \in \mathcal{I}_j (\exists \mathbf{p}_i \in I_i, \mathbf{p}_j \in I_j (||\mathbf{p}_j - \mathbf{p}_i|| \leq d_{\max})) \quad \forall \mathcal{K}_i, \mathcal{K}_j \in C.$$

In Worten bedeutet dies, dass alle zusammenzufassenden Bereiche paarweise jeweils ein Lanelet gemein haben müssen und dass der Abstand der einander nächsten Punkte \mathbf{p}_i und \mathbf{p}_j in den kritischen Intervallen eine Maximaldistanz d_{\max} nicht überschreiten darf.

Um ein solches Clustering umzusetzen, kann zum Beispiel ein agglomeratives Clustering-Verfahren benutzt werden, in welchem in jedem Schritt die Bedingung überprüft wird. Das Ergebnis dieses Clusterings ist in der Regel nicht

eindeutig und kann potenziell optimiert werden, was jedoch für den weiteren Verlauf dieser Arbeit nicht notwendig ist. Für jeden so erhaltenen Cluster wird nun ein einziger neuer Bereich initialisiert, der sich aus allen Lanelets und Intervallen in diesem Cluster zusammen- und selbige ersetzt. Da sich diese neu entstandenen Bereiche sowohl aus Entscheidungs- wie auch Konfliktbereichen zusammensetzen können, wird im Folgenden verallgemeinernd nur noch von kritischen Bereichen geschrieben, auch wenn Entscheidungs-, Konfliktbereiche oder eine Kombination beider gemeint sind. Abb. 3.3 zeigt beispielhaft das Ergebnis dieser Analyse für das gewählte Beispielszenario.

Als nächster Schritt werden alle so identifizierten kritischen Bereiche abgespeichert, um in den nächsten Kapiteln als Orte verwendet zu werden, für die das intendierte Verhalten der Fahrzeuge geschätzt und prädictiert werden soll. Dies geschieht in Form einer Abbildung von Lanelets auf kritische Bereiche, welche für jedes Lanelet alle kritischen Bereiche, in die es involviert ist, realisiert. Die Lanelet-Karte zusammen mit dieser Abbildung ermöglichen es nun im Folgenden, für beliebige Fahrzeuge effizient alle in naher Zukunft möglichen, ortsgebundenen Interaktionen, die in der Karte möglich sind, zu identifizieren.

3.4 Verkehrsregeln

Neben den topologischen Eigenschaften und daraus abgeleiteten kritischen Bereichen sind in der Lanelet-Karte ebenfalls semantische Informationen über geltende Verkehrsregeln hinterlegt. Bei den für diese Arbeit wichtigsten Verkehrsregeln handelt es sich um die Geschwindigkeitsbegrenzungen sowie die geltenden Vorfahrtsregeln. Die Geschwindigkeitsbegrenzungen werden benötigt, um gemeinsam mit der Straßentopologie und -topographie Annahmen über die geplanten Geschwindigkeiten der Fahrzeuge auf einzelnen Verkehrsabschnitten treffen zu können. Davon ausgehend, dass die betrachteten Fahrzeuge die vorgegebenen Geschwindigkeitsbegrenzungen nicht wesentlich überschreiten, kann abgeschätzt werden, welche kritischen Bereiche innerhalb eines gegebenen Prädiktionshorizonts erreicht werden können.

Die geltenden Vorfahrtsregeln auf der anderen Seite werden benutzt, um eine initiale Abschätzung über die Wahrscheinlichkeit zu bekommen, dass ein gegebenes Fahrzeug einen kritischen Bereich vor einem anderen Fahrzeug

durchqueren wird. Des Weiteren wird die Umsetzung der Vorfahrt (bzw. Vorrang) im Kontext dieser Arbeit so interpretiert, dass davon ausgegangen wird, dass das Fahrzeug, welches zuerst fährt, so fahren kann, als gäbe es das andere Fahrzeug gar nicht.

Diese Annahme wird mit der Formulierung aus der deutschen StVO begründet: „Es darf nur weitergefahren werden, wenn übersehen werden kann, dass wer die Vorfahrt hat, weder gefährdet noch wesentlich behindert wird“ (§8 Absatz 2 StVO [StV23a]). Konkret wird dies hier so interpretiert, dass davon ausgegangen werden kann, dass in verkehrsregelkonformen Situationen, in welchen mehrere Fahrzeuge zu ähnlichen Zeitpunkten einen durch Vorfahrt geregelten, kritischen Bereich erreichen, das vorrangige Fahrzeug sich in der Situation so verhalten kann, als gäbe es die anderen Fahrzeuge nicht. Dies erlaubt es nun, dem Ablauf solcher Situationen, trotz Interaktivität zwischen Fahrzeugen, eine hierarchische Struktur zu geben. Unter der Annahme, dass in den meisten Verkehrssituationen alle Teilnehmer bemüht sind, sich an die geltenden Verkehrsregeln zu halten, können nun durch diese Analyse der Vorfahrtsregeln, nur auf Basis der aktuellen Fahrzeugpositionen, wahrscheinliche Verhaltensweisen identifiziert werden.

International lässt sich diese Annahme auch in vielen anderen Ländern dieser Welt rechtfertigen. Die österreichische Straßenverkehrsordnung beispielsweise deklariert ähnlich wie in der deutschen: „Wer keinen Vorrang hat (der Wartepflichtige), darf durch Kreuzen, Einbiegen oder Einordnen die Lenker von Fahrzeugen mit Vorrang (die Vorrangberechtigten) weder zu unvermitteltem Bremsen noch zum Ablenken ihrer Fahrzeuge nötigen“ (§19 Absatz 8 der österreichischen StVO [StV23b]). In vielen weiteren Ländern wird zudem in unterschiedlichen Formen das Wiener Übereinkommen über den Straßenverkehr [Com68] umgesetzt, in welchem grundlegende Verkehrsregeln festgelegt sind, die in den Straßenverkehrsordnungen der teilnehmenden Länder zu realisieren sind. Während dieses Abkommen keine Definition darüber liefert, wie das Gewähren von Vorfahrt aussieht, legt es mehrere Verkehrssituationen und darin geltende Vorfahrtsregeln fest. Hierunter fällt beispielsweise die Rechtsvor-links-Regel für Länder mit Rechtsverkehr, welche im Kontext dieser Arbeit mehrfach Anwendung findet. Eine Eigenschaft, die alle in diesem Vertrag definierten Vorfahrtsregeln haben, ist, dass nur basierend auf statischen Informationen, wie die Topologie der Fahrstreifen, bereits Aussagen getroffen werden können, welche Fahrzeuge jeweils einander Vorfahrt gewähren müssen. Dies ist

eine wichtige und auf die meisten Verkehrssituationen zutreffende Eigenschaft, welche zum einen die Prädiktion von Fahrzeugverhalten in Vorfahrtsituation erheblich begünstigt und zum anderen bedeutet, dass in den meisten Situationen alle für die Vorfahrt relevanten Informationen in der Planungskarte gespeichert und aus selbiger gelesen werden können.

Es gibt allerdings auch vereinzelte Länder, in welchen sich die Vorfahrt in einigen Situationen erst aus der dynamischen Entwicklung der Verkehrssituation heraus ergibt. Die in Datensätzen am häufigsten vorkommende Verkehrssituation, welche in diese Kategorie fällt, ist der sogenannte All-Way Stop, welcher in einigen Bundesstaaten der Vereinigten Staaten von Amerika anstatt der Rechts-vor-links-Regel in Kreuzungssituationen Anwendung findet. Während die genaue Formulierung der Umsetzung dieser Regelung sich je nach Bundesstaat unterscheidet, gilt im Allgemeinen, dass immer das Fahrzeug, welches zuerst an der seiner Fahrspur zugewiesenen Haltelinie zum Stehen kommt, auch zuerst wieder losfahren darf und somit Vorfahrt hat. Dies stellt für Prädiktionsansätze ein erhebliches Problem dar, da sich in diesen Situationen oft erst sehr kurzfristig entscheidet, wie sich die Verkehrssituation verkehrsregelkonform entwickeln kann und es nicht immer möglich ist, akkurat vorherzusagen, welches Fahrzeug zuerst vollständig zum Stehen kommt. Im Kontext dieser Arbeit wird diese Situation nicht explizit modelliert, sie taucht jedoch in der Evaluierung des vorgestellten Ansatzes auf.

3.5 Abhängigkeitsgraphen

Der nächste Schritt in der Modellierung von Fahrzeuginteraktionen besteht darin, die aus der Karte gewonnenen Informationen zu benutzen, um für eine gegebene Verkehrssituation zu untersuchen, welche Fahrzeuge aufeinander achten müssen. Um dies umzusetzen, werden zunächst jedem Fahrzeug alle Lanelets zugeordnet, auf welchen es sich aktuell befindet. Hierbei handelt es sich im Allgemeinen um mindestens ein Lanelet, da sich das Fahrzeug andernfalls nicht im als befahrbar markierten Bereich der Karte befindet und somit nicht kartenbasiert prädiiziert werden kann. Außerdem werden alle Lanelets aus diesen Zuordnungen aussortiert, auf denen sich die Fahrzeuge zwar befinden, deren erlaubten Fahrtrichtungen jedoch nicht zu den Orientierungen der Fahrzeuge passen. Hierzu wird die Orientierung des Fahrzeugs mit allen

erlaubten Fahrtrichtungen der zugeordneten Lanelets verglichen und, falls der Betrag der Orientierungsabweichung ω größer als ein gewählter Schwellwert θ_ω ist, entfernt. Dies entfernt beispielsweise die Zuordnungen zu Lanelets, die in einer Kreuzungssituation orthogonal zu dem eigentlich befahrenen Pfad des Fahrzeugs orientiert sind. Basierend auf den verbleibenden Zuordnungen werden als Nächstes alle möglichen Pfade, die jedes dieser Fahrzeuge ausgehend von der aktuellen Position innerhalb eines gegebenen Prädiktionshorizontes verfolgen kann, berechnet.

Um zu identifizieren, welche Fahrzeuge einander in ihrem Verhalten gegenseitig beeinflussen können, werden als nächster Schritt die Lanelets, die auf jedem dieser Pfade liegen, mit den Lanelets aller Pfade aller anderen Fahrzeuge verglichen. Dasselbe wird für die auf den Pfaden liegenden Konfliktbereiche wiederholt, um alle Arten von Konfliktbereichen abdecken zu können. Auf diese Weise erhält man für jedes Fahrzeug alle anderen Fahrzeuge, welche in der nahen Zukunft auf einem ihrer Pfade dasselbe Lanelet oder denselben Konfliktbereich wie das betrachtete Fahrzeug passieren können. Einen Sonderfall beschreiben hierbei die Abhängigkeiten, welche durch Folgefahrten auftreten. Da in diesem Fall immer nur das hintere Fahrzeug das Verhalten des vorausfahrenden berücksichtigen muss, werden die Abhängigkeiten in diesen Fällen nur in eine Richtung betrachtet.

Bei den Pfaden unterschiedlicher Fahrzeuge, welche innerhalb des Prädiktionshorizonts Überlappungen auf Lanelet- oder Konfliktbereichseben aufweisen und sich nicht in einer unidirektionalen Abhängigkeit (z.B. einer Folgefahrt) befinden, wird hier von in Konflikt stehenden (oder konfligierenden) Pfaden gesprochen. Für die Befahrung zweier solcher in Konflikt stehenden Pfade muss nun gelten, dass es eine Reihenfolge geben muss, in welcher die überlappenden Verkehrsbereiche von den beiden Fahrzeugen befahren werden. Prädiziert man das Verhalten der Fahrzeuge in derselben Reihenfolge, wobei jede spätere Prädiktion die vorherigen berücksichtigt, so kann unter den bisher getroffenen Annahmen die Interaktion aller beteiligten Fahrzeuge in diesen Punkten vorhergesagt werden.

Diese konfligierenden Bereiche ebenso wie diese Reihenfolgen lassen sich in Form eines gerichteten Abhängigkeitsgraphen formalisieren. Um dies umzusetzen, wird zunächst gegeben einer Menge von relevanten Fahrzeugen C die Menge aller in naher Zukunft möglicherweise befahrener Pfade $\mathcal{P} = \{p_{ij}\}$ definiert. In diesem Kontext bezeichnet der einzelne Pfad p_{ij} den Pfad Nummer j




Abbildung 3.6: Ein Beispiel für eine Verkehrssituation aus [ZSW⁺19], in welcher die möglichen Pfade mehrere Fahrzeuge miteinander in Konflikt stehen.

von Fahrzeug $c_i \in C$. Diese Menge aller relevanter Pfade bildet die Grundlage in Form der Knoten für den zu konstruierenden Graphen $G = (V, E)$, $V = \mathcal{P}$. Die Kantenmenge E des Graphen sei die Menge der gerichteten Abhängigkeiten zwischen diesen Pfaden. Es wird definiert, dass Pfad p_{ij} des Fahrzeugs c_i von dem Pfad p_{kl} eines anderen Fahrzeugs c_k genau dann abhängt, falls die Pfade miteinander konfligieren und c_k den entsprechenden kritischen Bereich seines Pfades voraussichtlich durchfährt, bevor c_i dies für p_{ij} tut, oder falls c_i entlang dem Pfad p_{ij} dem Fahrzeug c_k folgt. Anschaulich kann dies anhand der Situation in Abb. 3.7 erklärt werden. Wie in Abb. 3.6 zu sehen, handelt es sich hier um eine Verkehrssituation auf dem bereits eingeführten Ausschnitt aus dem INTERACTION Datensatz mit insgesamt fünf Fahrzeugen, die sich an unterschiedlichen Punkten ihrer Durchfahrung der Szene befinden.

Zur Veranschaulichung wird nun das orange gefärbte Fahrzeug in dieser Situation genauer betrachtet. Man kann sehen, dass es sich genau an einem kritischen Bereich des Kreisverkehrs befindet, welche für diese Szene in Abb. 3.3 illustriert sind. Da es sich bei diesem kritischen Bereich unter anderem um einen Entscheidungspunkt handelt, gehen von diesem mehrere mögliche Folgepfade aus. Zu diesem Zeitpunkt ist noch nicht bekannt, ob das Fahrzeug in den nächsten Zeitschritten im Kreisverkehr bleiben (Pfad 1) oder selbigen verlas-

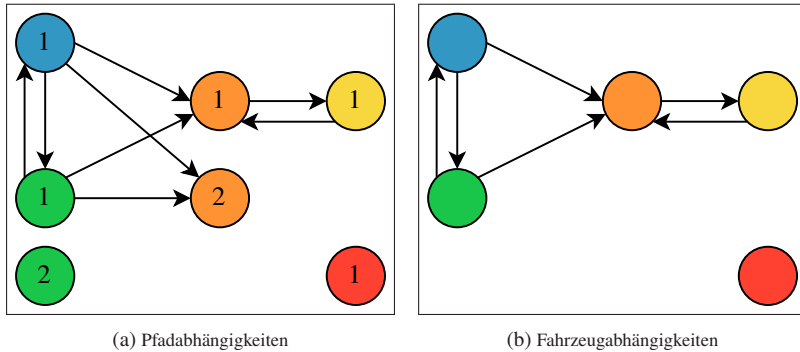


Abbildung 3.7: Die Abhängigkeitsgraphen, welche aus dem Szenario in Abb. 3.6 entstehen. 3.7a zeigt den entstehenden Abhängigkeitsgraphen auf Pfadebene und 3.7b zeigt die vereinfachte Darstellung auf Fahrzeugebene die insbesondere im Evaluationskapitel benutzt werden wird.

sen wird (Pfad 2). Falls dieses Fahrzeug Pfad 1 folgen wird, so gibt es einen Konflikt mit dem gelben Fahrzeug in einem weiteren kritischen Bereich. Es ist sowohl möglich, dass das gelbe Fahrzeug in den Kreisverkehr fahren wird, bevor das betrachtete Fahrzeug sich dem kritischen Bereich nähert, als auch, dass der entsprechende Bereich zuerst vom betrachteten Fahrzeug durchfahren werden wird. In erstem Fall bestünde eine Abhängigkeit des Pfades 1 des orangenen Fahrzeugs zum (einzigen) Pfad 1 des gelben Fahrzeugs. Gewährt das gelbe Fahrzeug hingegen die Vorfahrt, so bestünde die Abhängigkeit im umgekehrten Sinne. Die grün und blau gefärbten Fahrzeuge hingegen haben nicht mehr die Möglichkeit, vor dem betrachteten Fahrzeug in den Kreisverkehr einzufahren. Entsprechend sind in diesen Fällen die Abhängigkeiten zum Pfad des orangenen Fahrzeugs nur unidirektional. Das letzte (rote) Fahrzeug hingegen steht in keiner Relation zum betrachteten Fahrzeug, da es sich außerhalb der betrachteten direkten Umgebung des orangenen Fahrzeugs befindet.

Führt man diese Analyse für alle Fahrzeuge durch, so erhält man den aus dieser Situation entstehenden Abhängigkeitsgraphen, welcher in Abb. 3.7a abgebildet ist. Der hier abgebildete Graph zeigt lediglich Abhängigkeiten, die an den jeweils nächsten kritischen Bereichen zwischen den Fahrzeugen entstehen. Dies entspricht einem geringen Prädiktionshorizont. In der Praxis entstehen in Situationen mit mehreren kritischen Bereichen in naher Umgebung

und bei Verwendung von größeren Zeithorizonten erheblich mehr Pfadabhängigkeiten. Hier wären das beispielsweise Abhängigkeiten zwischen dem gelben Fahrzeug und den weiteren Pfadmöglichkeiten des grünen und des blauen Fahrzeuges, die sich am kritischen Bereich, in welchem sich das orange Fahrzeug befindet, ergeben. Um dennoch eine geeignete Visualisierung liefern zu können, wird außerdem eine vereinfachte Form des Abhängigkeitsgraphen eingeführt, die in Abb. 3.7b zu sehen ist. Der Fahrzeugabhängigkeitsgraph definiert sich über den (Pfad-)Abhängigkeitsgraphen, indem alle Knoten, die zu demselben Fahrzeug gehören, zu einem Knoten vereint werden $V' = \{v_i | \exists i, j : p_{ij} \in V\}$ und die Abhängigkeiten zu den anderen Fahrzeugen erhalten bleibt $E' = \{(v_i, v_k) | \exists i, j, k, l : (p_{ij}, p_{kl}) \in E\}$.

3.6 Hierarchische Strukturierung von Abhängigkeitsrelationen




Abbildung 3.8: Mögliche topologische Sortierungen von 3.7a und 3.7b unter Berücksichtigung von geltenden Vorfahrtsregeln, wodurch gestrichelte Kanten ausgeschlossen wurden.

Hat man den Abhängigkeitsgraphen berechnet, kann man diesen benutzen, um herauszufinden, wie und in welcher Reihenfolge die Fahrzeuge für eine Verhaltensvorhersage betrachtet werden sollten. An dieser Stelle greift die Annahme, welche in Abschnitt 3.4 eingeführt wurde, dass Fahrzeuge, die Vorfahrt haben, so fahren können, als gäbe es Fahrzeuge mit Nachrang nicht. In dem betrachteten Beispiel hieße dies, dass die Abhängigkeiten des orangen Pfads 1 vom gelben Pfad ebenso wie die Abhängigkeit des grünen Pfads 1 vom blauen Pfad

vernachlässigt werden können, da beide Male die in den Kreisverkehr einfahrenden Fahrzeuge Nachrang haben. Unter dieser Annahme ist nun eine echte topologische Sortierung möglich. Anschaulich bedeutet dies, dass es möglich ist, die Knoten eines gerichteten Graphen linear so anzuordnen, dass alle Kanten zwischen den Knoten in dieselbe Richtung zeigen. Im Allgemeinen gilt für einen beliebigen gerichteten Graphen $G = (V, E)$, dass genau dann eine topologische Sortierung des Graphen möglich ist, wenn eine bijektive Abbildung $\Phi : V \rightarrow N \subseteq \mathbb{N}$ auf eine Teilmenge N der natürlichen Zahlen existiert, sodass gilt: $\forall (v_i, v_j) \in E : \Phi(v_i) < \Phi(v_j)$. Abb. 3.8 zeigt jeweils für beide Darstellungsformen des Abhängigkeitsgraphen des betrachteten Beispiels, wie eine solche topologische Sortierung aussehen kann. Hierbei ist zu beachten, dass topologische Sortierungen im Allgemeinen nicht eindeutig sind, da beispielsweise Knoten, die keine Kanten haben, wie in dem Beispiel der Knoten für das rot gefärbte Fahrzeug, an beliebiger Stelle der Sortierung stehen können.

Hat man für einen Abhängigkeitsgraphen eine topologische Sortierung gefunden, so hat man dadurch automatisch ebenfalls eine Reihenfolge gefunden, in welcher die Fahrzeuge prädiiziert werden können, ohne dass der Pfad eines Fahrzeuges von dem eines anderen Fahrzeuges welches später prädiiziert werden soll, abhängig ist. Ist es möglich, eine topologische Sortierung zu finden, so haben alle möglichen Sortierungen die Eigenschaft, dass sie für jedes Paar von Fahrzeugen, die auf einen gemeinsamen kritischen Bereich zufahren, dieselbe Durchfahrungsreihenfolge vorgeben. Diese Reihenfolge gibt jeweils für eine Verkehrssituation, die sich an einem kritischen Bereich abspielt, eine Homotopieklasse vor, wie sie für mehrere Agenten in [SHL⁺17] definiert wurde. Somit gibt auch jeder topologisch sortierbare Abhängigkeitsgraph für jeden kritischen Bereich und jede Menge von Fahrzeugen, die denselben Bereich durchfahren, eine eindeutige gemeinsame Homotopieklasse aller beteiligter Fahrzeuge vor. Wird im Folgenden von einer Homotopieklasse geschrieben, so ist jeweils eine einzelne Durchfahrungsreihenfolge für einen bestimmten kritischen Bereich gemeint.

Wie man in dem gegebenen Beispiel sehen kann, ist es jedoch nicht im Allgemeinen gegeben, dass sich eine topologische Sortierung für beliebige Abhängigkeitsgraphen finden lässt. In dem gewählten Beispiel mussten zunächst zwei Kanten des ursprünglichen Abhängigkeitsgraphen entfernt werden, um eine solche Sortierung finden zu können. Da es möglich ist, dass die Vorfahrtsregeln keine eindeutige Reihenfolge festlegen oder dass sich nicht alle

Fahrzeuge an die gegebenen Vorfahrtsregeln halten, kann man eine gegebene Verkehrssituation in der Regel nicht auf einen einzigen möglichen topologisch sortierten Abhängigkeitsgraphen reduzieren. Dennoch ist es offensichtlicherweise so, dass wenn man den tatsächlichen Verlauf der Verkehrssituation über die nächsten Zeitschritte ansieht, nur eine Reihenfolge der Fahrzeugdurchfahrten für jeden Bereich eintritt.

Da es aus kombinatorischen Gründen nicht sinnvoll ist, alle möglichen Kombinationen, wie man Abhängigkeitsrelationen eines Graphen entfernen kann, um einen topologisch sortierbaren Graphen zu erhalten, durchzuprobieren, ist der nächste Schritt, eine Kantengewichtungsfunktion $g : V^2 \rightarrow [0, 1]$ einzuführen, welche es nun erlaubt, diese Möglichkeiten zu bewerten. Auf die Berechnung von g wird in Abschnitt 3.7 genauer eingegangen und an dieser Stelle wird zunächst nur vorgegeben, dass $g(v_i, v_j) = 0$, falls $(v_i, v_j) \notin E$, und andernfalls $0 < g(v_i, v_j) \leq 1$. Diese Gewichtungsfunktion wird hier als die bedingte Wahrscheinlichkeit, dass eine Abhängigkeit in der gegebenen Richtung zwischen zwei Fahrzeugpfaden besteht, gegeben, dass beide Fahrzeuge die Intention haben, dem entsprechenden Pfad zu folgen, interpretiert. Gegeben einer solchen Funktion g kann für jede Abbildung $\Phi : V \rightarrow N \subseteq \mathbb{N}$, welche eine Sortierung vorgibt, eine Bewertungsfunktion s definiert werden, welche die Gewichte aller Kanten „in Gegenrichtung der Sortierung“ aufsummiert:

$$s(V, E, \Phi, g) = \sum_{i \in N} \sum_{j > i, j \in N} g((\Phi^{-1}(j), \Phi^{-1}(i))) \quad (3.1)$$

Gibt Φ eine topologische Sortierung des Graphen vor, so ist dieser Wert 0. Andernfalls gibt sie an, wie stark diese Abbildung von einer topologischen Sortierung abweicht.

Mithilfe dieser Bewertungsfunktion ist es nun möglich, für beliebige Abhängigkeitsgraphen gegeben einer Kantengewichtungsfunktion g die bestmögliche Sortierung zu finden. Dies entspricht der Suche nach einer Abbildung Φ , für welche s minimiert wird. In der Graphentheorie ist dieses Problem äquivalent zum Minimum Feedback Arc Set Problem, welches 1963 das erste Mal von D. Younger [You63] formuliert wurde. Ein Feedback Arc Set beschreibt eine Teilmenge der Kanten eines Graphen, durch deren Entfernung dieser azyklisch wird. Sowohl das zugehörige Entscheidungsproblem, ob eine solche Teilmenge mit einer Kardinalität kleiner einem gegebenen Wert existiert, als auch das Optimierungsproblem, diese Menge mit kleinstmöglicher Kardinalität zu fin-




Abbildung 3.9: Die beiden kleinstmöglichen nicht-planaren Graphen K_5 und $K_{3,3}$. Nach dem Satz von Kuratowski [Kur30] muss jeder nicht-planare Graph mindestens einen dieser beiden Graphen als Graph-Minoren haben.

den, gehören für beliebige Graphen zu den NP-schweren Problemen und sind somit nach heutigem Wissensstand nicht effizient lösbar. Eine Ausnahme gibt es allerdings für planare Graphen. Es wurde in [LY78] gezeigt, dass sich bei diesen mit polynomielltem Aufwand beide Probleme lösen lassen. Der zugehörige Algorithmus, welcher dies für gewichtete Graphen in $O(n^3)$ umsetzt, wurde erstmals in [Gab95] dargelegt. Weitere Details über dieses Problem finden sich in [BJG08].

Zwar ließen sich theoretisch Situationen konstruieren, in welchen die Planarität der jeweiligen Abhängigkeitsgraphen nicht gegeben ist, diese sind jedoch in realen Verkehrssituationen äußerst unwahrscheinlich und erhöhen den Verarbeitungsaufwand, so sie denn auftreten, nur geringfügig, sodass die Effizienz des Algorithmus im Durchschnitt gegeben ist. Dies lässt sich mit dem Satz von Kuratowski zur Planarität von Graphen [Kur30] begründen, welcher besagt, dass ein Graph genau dann nicht planar ist, wenn er keinen Teilgraphen besitzt, der ein Unterteilungsgraph des vollständigen Graphen mit fünf Knoten K_5 oder des vollständig bipartiten Graphen mit je drei Knoten $K_{3,3}$ ist. Diese Bedingung ist in Abb. 3.9 veranschaulicht. Bezogen auf die hier beschriebene Domäne hieße das im ersten Fall, dass mindestens fünf Abhängigkeitsverkettungen von Pfaden mit jedem der anderen dieser Pfade oder deren Verkettung in Konflikt stehen müssten (K_5). In den meisten Straßentopologien hieße das, dass

zugleich auch mindestens 5 Fahrzeuge an diesem konkreten Abhängigkeits-
teilgraphen beteiligt sein müssen, da Abhängigkeiten zu anderen Pfaden des
eigenen Fahrzeugs nur indirekt entstehen können. Der zweite Fall ($K_{3,3}$) hie-
ße, dass insgesamt sechs Pfade (oder Abhängigkeitsverkettungen derselbigen)
in zirkulären Abhängigkeiten zueinander stehen müssten. Dies ist mit ähnli-
cher Begründung wie in Fall 1 äußerst unwahrscheinlich, was sich auch in der
Evaluation in Kapitel 6 bestätigt.

Somit ist die generelle Skalierbarkeit dieses Ansatzes, wenn auch nicht vollum-
fänglich bewiesen, zumindest sehr nahegelegt. In der praktischen Anwendung
ist die Verwendung dieses optimalen Algorithmus, welcher auf die Worstcase-
Betrachtungen von hochkomplexen Graphen optimiert ist, jedoch sprichwört-
lich „mit Kanonen auf Spatzen geschossen“. In einer überwiegenden Anzahl
der natürlich vorkommenden Verkehrssituationen bestehen die auftretenden
Zyklen hauptsächlich aus gegenseitigen Abhängigkeiten zwischen einzelnen
Fahrzeugen oder einer sehr kleinen Menge an Fahrzeugen, wie auch am Bei-
spiel in Abb. 3.8 ersichtlich. Für die effiziente Eliminierung dieser Zyklen
werden im Kontext dieser Arbeit zunächst alle Knoten entfernt, die entwe-
der keine Eingangs- oder Ausgangs-Kanten haben, da diese nicht Teil eines
Zyklus sein können und somit keine derer Kanten entfernt werden muss. Als
Nächstes wird eine Reihe von Tiefensuchen (DFS) auf dem verbleibenden Gra-
phen durchgeführt. Hierbei werden alle Kanten, welche im Tiefensuchbaum
zurück zu bereits besuchten Knoten zeigen, benutzt, um Zyklen zu finden. Je-
de einzelne dieser Kanten induziert einen Zyklus bestehend aus dem Teil des
Suchbaums, welcher zu der zurückführenden Kante führt. Falls am Ende einer
Suche noch nicht alle Knoten besucht wurden, beispielsweise weil der Graph
aus mehreren nicht untereinander verbundenen Teilgraphen besteht, wird eine
neue Suche auf einem der verbleibenden Knoten gestartet. Das Ergebnis die-
ses Algorithmus ist eine Liste von Zyklen, von denen jeweils mindestens eine
Kante entfernt werden muss, um den Graphen azyklisch und somit topologisch
sortierbar zu machen. Da diese Liste von Zyklen insbesondere die Menge aller
gegenseitigen Abhängigkeiten als Teilmenge hat, also alle Zyklen der Größe
zwei, werden diese zunächst betrachtet und deren Kantenbewertungen mitein-
ander verglichen. Durch die Auswahl und Entfernung der jeweils kleinsten
Kanten kann der Graph bereits erheblich vereinfacht werden. Anschließend
werden die verbleibenden Zyklen untersucht und das Vorgehen wiederholt.
Dieser Ansatz verfolgt eine Strategie ähnlich der, welche bei Algorithmen der
dynamischen Programmierung Anwendung findet. Jedoch ist es nicht gegeben,

dass eine lokal optimale Teillösung, nämlich die Auswahl der kleineren Kante in gegenseitigen Abhängigkeiten, auch zu optimalen Gesamtlösungen führt. Da wir für den weiteren Verlauf des hier beschriebenen Ansatzes allerdings die Optimalität gegen den Aufwand der vollständigen Berechnung abwägen müssen, wurde dieser Weg gewählt, um schnell und effizient nicht nur eine einzelne gute Lösung zu finden, sondern durch Variation der ausgewählten Kanten auf Basis der individuellen Wahrscheinlichkeit schnell weitere Lösungen, welche ähnlich gut sind, finden zu können. Die so gewonnenen Ergebnisse geben die Reihenfolge, in welcher Simulationen in Kapitel 4 durchgeführt werden, vor.

3.7 Bewertung von Abhängigkeitsrelationen

Wie zuvor in Abschnitt 3.6 eingeführt, werden die Abhängigkeiten des gerichteten Abhängigkeitsgraphen durch eine Gewichtungsfunktion g bewertet. Die Idee hinter dieser Funktion ist es, die Wahrscheinlichkeit zu beurteilen, dass tatsächlich eine Abhängigkeitsrelation zwischen den entsprechenden Fahrzeugen beim Befahren der entsprechenden Pfade besteht. Um dies abschließend beurteilen zu können, ist die Intentionsschätzung notwendig, welche in Kapitel 5 eingeführt wird und die Berechnung dieser Größe ermöglicht. Da diese Intention über mehrere Zeitschritte hinweg iterativ berechnet wird, ist jedoch eine Ausgangsbewertung der Situation lediglich auf Basis der äußeren Begebenheiten notwendig. Diese wird umgesetzt, indem die Zeit geschätzt wird, die die einzelnen Fahrzeuge jeweils benötigen, um den entsprechenden kritischen Bereich zu erreichen. Anschließend werden die errechneten Zeiten zueinander in Relation gesetzt, um die miteinander in Konflikt stehenden Pfade gegeneinander zu bewerten. Das Ergebnis dessen wird als Grundlage für die Initialisierung der Intentionswahrscheinlichkeiten im kommenden Kapitel 5 verwendet.

Zur Berechnung der Ankunftszeit t_{ik} des Fahrzeugs c_i an den kritischen Bereichen k werden abhängig vom Zustand des Fahrzeugs entweder eine gleichmäßig beschleunigte Bewegung mit Beschleunigung a_i , eine konstante Bewegung mit Geschwindigkeit v_i oder ein konstanter, hoher Wert t_c angenommen. Es

ergibt sich für die geschätzte Zeit zum kritischen Bereich in Distanz s_{ik} entlang des gewählten Pfades folgende Formel:

$$t_{ik} = \begin{cases} p_{\S} \cdot \frac{1}{a_i} \cdot \left(-v_i + \sqrt{v_i^2 + 2a_i s_{ik}} \right) & \text{falls } a_i \neq 0 \wedge v_i^2 + 2a_i s_{ik} > 0 \\ p_{\S} \cdot \frac{s_{ik}}{v_i} & \text{sonst, falls } v_i > 0 \\ t_c & \text{sonst} \end{cases} \quad (3.2)$$

Der Vorfaktor p_{\S} ebenso wie der Wert t_c sind hierbei Modellparameter. Der Wert für p_{\S} nimmt für Fahrzeuge, welche entweder Vorfahrt haben oder nicht durch Vorfahrtsregeln beeinflusst sind, den Wert 1 an. Für alle anderen Fahrzeuge (diejenigen mit Nachrang) ist der Wert eine konstante Zahl größer 1, was symbolisiert, dass das entsprechende Fahrzeug bei ähnlicher Ankunftszeit verzögern und Rücksicht auf andere Fahrzeuge nehmen muss. Der Wert der Funktion g wird, nachdem diese Zeiten für die Fahrzeuge c_i und c_j , welche auf denselben kritischen Bereich k zusteuern, entlang ihrer jeweiligen Pfade p_{il} bzw. p_{jm} berechnet wurden, abhängig von ihrem Anteil der Gesamtzeit gesetzt:

$$g_0((p_{il}, p_{jm})) = \frac{t_{jk}}{t_{ik} + t_{jk}} \quad (3.3)$$

Diese Berechnungen werden immer dann paarweise für Fahrzeuge ausgeführt, wenn sich neue Interaktionen durch den Verlauf der Szene ergeben. Das ist immer dann der Fall, wenn ein neuer kritischer Bereich, auf den ein anderes Fahrzeug zufährt, in den Prädiktionshorizont eines Fahrzeugs rückt, oder ein neues Fahrzeug in der Szene auftaucht. Für Veränderungen, welche sich aus neuen Beobachtungen der Szene ergeben, werden diese Berechnungen nicht erneut ausgeführt, sondern stattdessen die Intentionswahrscheinlichkeiten herangezogen, welche in Kapitel 5 berechnet werden. Der Grund hierfür liegt darin, dass die hier gezeigten Formeln lediglich eine sehr ungenaue Abschätzung der Wahrscheinlichkeiten bieten. Dadurch, dass lediglich die Distanzen und der aktuelle Fahrzeugzustand betrachtet werden, werden genau die Abhängigkeiten zwischen Fahrzeugen, welche sich aus Interaktionen ergeben und welche abgeschätzt werden sollen, ignoriert. Somit handelt es sich hier lediglich um Initialschätzungen (daher auch der Index 0), welche die Ausgangswerte

für die Algorithmen in den folgenden Kapiteln angeben. Für den allgemeinen Fall ergibt sich stattdessen die Formel:

$$g_t((p_{il}, p_{jm})) = \begin{cases} 1 - \frac{t_{ik}}{t_{ik} + t_{jk}} & t = 0 \\ P_t(s_{ij}|o_{0:t}) & \text{sonst} \end{cases} \quad (3.4)$$

Hierbei repräsentiert s_{ij} diejenige Intention von Fahrzeug i , welche symbolisiert, dass i vorhat, direkt nach Fahrzeug j den kritischen Bereich zu durchqueren, welcher die Pfade l und m verbindet. Die Berechnung dieser bedingten Wahrscheinlichkeit findet sich in Kapitel 5.

4 Trajektorienprädiktion

Dieses Kapitel der Dissertation beschäftigt sich mit dem Ansatz der Trajektorienprädiktion, welcher im Kontext der hier vorgestellten Methode Anwendung findet. Um die hohe Ähnlichkeit zwischen den Disziplinen der Trajektorienplanung für Fahrzeuge und der Prädiktion selbiger auszunutzen, wird in dem hier vorgestellten Ansatz auf einen Algorithmus der Trajektorienplanung zurückgegriffen. Durch die Planung von Trajektorien für die beobachteten Verkehrsteilnehmer entstehen Bewegungshypothesen, welche wiederum als Prädiktionen verwendet werden können.

Zunächst werden in Abschnitt 4.1 die für dieses Kapitel wesentlichen Begriffe definiert und das Kapitel in den Gesamtkontext der Arbeit eingegliedert. Anschließend wird in Abschnitt 4.2 gezeigt, wie die Ergebnisse des vorherigen Kapitels die Komplexität der Aufgabe verringern können. Abschnitt 4.3 führt das hier verwendete Prädiktionsmodell basierend auf einem gängigen Planungsalgorithmus ein. Als Nächstes zeigt Abschnitt 4.4, wie ortsgebundene Interaktionen in diesem Ansatz modelliert werden können. Zuletzt wird in Abschnitt 4.5 darauf eingegangen, wie die Häufigkeit, mit der der Planungsalgorithmus ausgeführt werden muss, verringert werden kann.

4.1 Planungsbasierte Prädiktion

Wie in Abschnitt 2.4 bereits kurz eingeführt, versuchen Ansätze zur Trajektorienprädiktion, mit unsicheren Informationen über Intentionen und (physische) Zustände anderer Verkehrsteilnehmer Aussagen über die Zustände dieser Fahrzeuge in der nahen Zukunft zu treffen. Eine Trajektorie $T = ((a_{1t_1}, a_{2t_1}, \dots), (a_{1t_2}, a_{2t_2}, \dots) \dots (a_{1t_h}, a_{2t_h}, \dots))$ bezeichnet im Kontext dieser Arbeit eine zeitlich geordnete Abfolge von Attributen (a_1, a_2, \dots) , welche die Bewegung eines Fahrzeugs zu den Zeitschritten t_1, t_2, \dots, t_h beschreiben. Da in diesem Kontext die Trajektorie vorhergesagt wird, ist die Länge selbiger durch

den Prädiktionshorizont h beschränkt. Ohne Beschränkung der Allgemeinheit wird außerdem in diesem Kontext angenommen, dass $t_n - t_{n-1} = 0,1s$ für alle Zeitschritte $n \in [0..h]$. Für die in einer Trajektorie enthaltenen Attribute (a_1, a_2, \dots) wird angenommen, dass sie mindestens 2D-Koordinaten der Fahrzeuge x, y in einem weltfesten Koordinatensystem sowie deren erste und zweite Ableitungen nach der Zeit, also jeweils die Geschwindigkeit und die Beschleunigung beinhalten $(x, y, \dot{x}, \dot{y}, \ddot{x}, \ddot{y})$. Hierbei wird vereinfachend angenommen, dass sich Fahrzeuge auf einer flachen (Boden-)Ebene bewegen und auf eine Punktmasse reduzieren lassen. Diese Annahme erfordert, dass die Form der Fahrzeuge zuverlässig getrackt werden kann, sodass sich der entsprechende Punkt in jedem Zeitschritt an derselben Stelle des Fahrzeugs befindet. Typischerweise handelt es sich hierbei entweder um den Mittelpunkt einer Boundingbox, welche um das Fahrzeug gelegt wird, oder um den geschätzten Mittelpunkt der Hinterachse des Fahrzeugs, um die Verwendung von dynamischen Fahrzeugmodellen zu vereinfachen. Kann dieser Punkt zuverlässig über alle Beobachtungsschritte geschätzt werden, kann basierend auf diesem ebenfalls die umgebende Hülle des Fahrzeugs zu jedem prädizierten Zeitpunkt geschlossen werden und die Reduktion auf eine einzelne Position ist unproblematisch.

Die Aufgabenstellung der Trajektorienprädiktion ist eng verwandt mit der Aufgabenstellung der Trajektorienplanung. In beiden Aufgabenbereichen ist das Ziel, für (mindestens) ein Fahrzeug eine Trajektorie zu bestimmen, welche in der aktuellen Situation *optimal* ist. Der wesentliche Unterschied ist es, dass bei der Trajektorienprädiktion Unsicherheit über den internen Zustand des Fahrzeugs, für welches diese Trajektorie erzeugt werden soll, besteht. Dennoch ist es möglich, Algorithmen, welche auch in der Trajektorienplanung für Fahrzeuge Anwendung finden, für die Trajektorienprädiktion zu verwenden. Man spricht bei diesen Methoden von „Prädiktion durch Simulation“ oder von „Prädiktion durch Planung“ [BDCK20].

Im Sinne des Informationsflusses im Kontext eines POSG, wie es in Abschnitt 2.1 eingeführt wurde, wird durch den Planungsvorgang die Auswahl der Aktion c_i beschrieben, welche den nächsten physischen Zustand des Akteurs beeinflusst. Dies ist in Abb. 4.1 hervorgehoben. Wie aus der Abbildung ersichtlich wird, ergeben sich die Trajektorienprädiktionen durch eine Sequenz von abwechselnder Planung und Simulation der nächsten Zeitschritte ausgehend von aktuellen Schätzungen der physischen und internen Zustände x_t und




Abbildung 4.1: Trajektorienprädiktion durch Planung im Kontext eines POSG. Der Planungsvorgang beschreibt in grün hervorgehoben die Auswahl der Aktionen der einzelnen Agenten. Basierend auf diesen Aktionen werden die neuen Zustände durch die in rot hervorgehobene Simulation berechnet. Die Trajektorien beschreiben die in gelb hervorgehobenen physischen Zustände der Zukunft.

s_t . Um eine Trajektorienprädiktion durch Planung umzusetzen, sind daher möglichst gute Schätzungen insbesondere der internen Zustände der einzelnen Fahrzeuge notwendig, welche die Parameter für den Planungsansatz liefern.

Die planungsbasierte Prädiktion selbst läuft im Allgemeinen wie folgt ab. Basierend auf dem angenommenen internen Zustand jedes einzelnen zu präzisierenden Fahrzeugs sowie den zur Verfügung stehenden Umgebungsinformationen werden Parameter ermittelt, welche der Algorithmus zur Trajektorienplanung benötigt. Diese gemeinsam mit der Annahme über den internen Zustand des Fahrzeugs werden als Hypothese H_i der Parameter für das Fahrzeug i bezeichnet, unter welcher die Simulation durchgeführt wird. Die Menge der Hypothesen über alle Fahrzeuge bestimmt, wie sich die Gesamtheit der Fahrzeuge unter der Annahme, dass sie den entsprechenden Planungsalgorithmus verwenden, bewegt. Unter der Annahme einer solchen Menge von Hypothesen wird nun ein einzelner Zeitschritt simuliert. Das Ergebnis dieser Simulation ist die Grundlage, auf welcher das Verhalten für den nächsten Zeitschritt geplant wird. Dieser Vorgang wird so lange wiederholt, bis das Ende des Prädiktionshorizonts h erreicht wurde. Die Trajektorien ergeben sich aus den einzelnen Simulationsergebnissen der Orte, an welchen sich die jeweiligen Fahrzeuge zu diesem Zeitpunkt aufgehalten haben.




Abbildung 4.2: Eine visuelle Darstellung der kombinatorischen Explosion, welche sich allein aus der Simulation aller möglichen Kombinationen von Intentionen mehrerer Fahrzeuge ergibt. Bereits unter der Annahme, dass für jedes der n Fahrzeuge nur 3 Hypothesen über den internen Zustand vorliegen, wird ersichtlich, dass bereits 3^n Simulationen der Situation notwendig sind, um alle Kombinationen abzudecken.

4.2 Komplexität von interaktiven Prädiktionsansätzen

Im Allgemeinen ist es nicht möglich, die Parameter und den internen Zustand der zu präzisierenden Fahrzeuge mit einem ausreichend hohen Grad an Sicherheit zu schätzen, sodass eine einzige Hypothese direkt das Simulationsergebnis liefert, welches tatsächlich durchfahren wird. Stattdessen müssen mehrere Hypothesen insbesondere über mehrere mögliche Intentionen, welche Teil des internen Zustands der Fahrzeuge sind, aufgestellt und überprüft werden. Jede dieser Hypothesen für jedes Fahrzeug, welches Teil der Verkehrssituation ist, führt zu unterschiedlichen Simulationsergebnissen in jedem Zeitschritt. Wie aus Abb. 4.1 ersichtlich, führt jedes dieser unterschiedlichen Ergebnisse zu Änderungen in den entsprechenden internen Zuständen, welche erneut simuliert werden müssen. Um die vollständige Menge der Kombinationen aller unterschiedlicher Intentionen durch simulative Prädiktion abzudecken, ist das Produkt der Anzahl aller möglichen Intentionen der einzelnen Fahrzeuge an Simulationen notwendig. Dies entspricht einer kombinatorischen Explosion und ist in Abb. 4.2 beispielhaft für drei Fahrzeuge mit jeweils drei möglichen Intentionen dargestellt.

Da die vollständige Simulation all dieser Kombinationen mit der Anzahl der beteiligten Fahrzeuge exponentiell und mit der Komplexität der Situation zu-




Abbildung 4.3: Eine topologische Sortierung, bei der Abhängigkeiten und Pfade ausgeschlossen wurden, da jeweils gegenläufige Hypothesen betrachtet werden.

sätzlich polynomiell skaliert, müssen Wege gefunden werden, entweder diese kombinatorische Explosion zu verhindern oder bereits im Vorfeld zu entscheiden, welche Hypothesen sinnvoller als andere sind und somit eher simuliert werden sollten. Einen Weg, die kombinatorische Anzahl an Simulationen zu verringern, ist auf Basis der Abhängigkeitsanalysen und Annahmen, welche in Kapitel 3 getroffen wurden, gegeben.

Durch die Aufstellung des Abhängigkeitsgraphen und die topologische Sortierung desselben kann bestimmt werden, welche Abhängigkeiten am wahrscheinlichsten auftreten und welche Fahrzeuge unabhängig voneinander simuliert werden können. Die Betrachtungsweise, die durch diesen Abhängigkeitsgraphen gegeben ist, gibt zugleich den Informationsfluss im POSG zwischen den physischen Zuständen über die Beobachtungen zu den jeweiligen internen Zuständen der Fahrzeuge vor. Es gibt für die Simulation nun keine Wechselwirkungen zwischen einzelnen Fahrzeugen, sondern lediglich unidirektionale Abhängigkeiten. Dies bedeutet, dass gegeben einer gefundenen topologischen Sortierung und jeweils einer Hypothese per Fahrzeug genau eine Simulation per Fahrzeug durchgeführt wird. Zur Illustration wird in Abb. 4.3 visualisiert, wie dies auf Basis der Situation, welche zuvor in Abb. 3.8 eingeführt wurde, umgesetzt wird. Durch die topologische Sortierung sowie die jeweils gewählten Hypothesen, welche unter anderem den intendierten Pfad der Fahrzeuge bestimmen, wird eine Vielzahl an Abhängigkeiten zwischen den Fahrzeugen ausgeschlossen, welche für die aktuelle Simulation nicht relevant sind. Anschlie-

Bend können die Fahrzeuge in umgekehrter Reihenfolge der topologischen Sortierung nacheinander bis zum Prädiktionshorizont simuliert werden und müssen dabei lediglich auf die zuvor bereits simulierten Fahrzeuge Rücksicht nehmen. Dieser Vorgang wird wiederholt, bis entweder alle möglichen Hypothesenkombinationen simuliert wurden oder ein Zeitpunkt erreicht wurde, an welchem neue Informationen verarbeitet werden sollen. Die Reihenfolge, in welcher die Hypothesenkombinationen simuliert werden, ergibt sich wiederum aus den möglichen topologischen Sortierungen sowie der Intentionsschätzung, welche in Kapitel 5 dargelegt wird.

4.3 Prädiktionsmodell

Wie aus den vorherigen Abschnitten ersichtlich, ist eins der Ziele dieser Arbeit, eine planungsbasierte Prädiktion umzusetzen. Für die Planung von automatisierten Fahrzeugen werden häufig optimierungsbasierte Ansätze verfolgt. Hierbei wird eine Vielzahl an Faktoren, welche Einfluss auf die Auswahl des Fahrzeugverhaltens haben, wie (Sicherheits-)Abstände zu anderen Objekten, durch die gewählten Aktionen entstehender Ruck, Kollisionswahrscheinlichkeiten etc. formalisiert und in einer Kostenfunktion vereint [Taş22]. Diese Kostenfunktion wird dann minimiert, während nach einer Lösung, das eigene Ziel zu erreichen, gesucht wird. In einem spieltheoretisch motivierten POSG entspricht dieser Vorgang der Auswahl der Aktionen c , welche ebenfalls in spieltheoretischen Modellierungen häufig durch die Maximierung einer Belohnungs- oder die Minimierung einer Kostenfunktion getroffen wird.

Da für die Prädiktion anderer Fahrzeuge in der Regel eine ungefähre Position ausreicht, sich Faktoren wie der Ruck nur minimal auf die ungefähre Position auswirken und weil es rechnerisch nicht sinnvoll ist, für jede Simulation aller Fahrzeuge diese Optimierungen durchzuführen, wird stattdessen ein stark vereinfachter Planungsansatz verfolgt. Die Basis für dieses Modell liefert das weit verbreitete Intelligent Driver Model (IDM), welches ursprünglich in [THH00] eingeführt wurde. Hierbei handelt es sich um eine Modellierung von longitudinalem Fahrverhalten in Situationen mit einem vorausfahrenden Fahrzeug.

Das Modell beschreibt die geplante Geschwindigkeitsänderung entlang der Fahrspur durch die Formel

$$\frac{dv}{dt} = \hat{a}_{\text{long}} \left[1 - \left(\frac{v}{v_0} \right)^\beta - \left(\frac{d^*(v, \Delta v)}{d} \right)^2 \right] \quad (4.1)$$

mit der Hilfsfunktion

$$d^*(v, \Delta v) = d_0 + vT + \frac{v\Delta v}{2\sqrt{\hat{a}_{\text{long}}b_{\text{comf}}}}. \quad (4.2)$$

In diesen Formeln beschreibt v die aktuelle Geschwindigkeit des zu planenden Fahrzeugs, d den Abstand zwischen den Fahrzeugen und $\Delta v = v - v'$ die Differenz zu der Geschwindigkeit v' des vorausfahrenden Fahrzeugs. Die weiteren Parameter dieser Gleichungen sind Teil des internen Zustands des Fahrzeugs und sind in Tabelle 4.1 gegeben.

| Parameter | Beschreibung | Einheit |
|-------------------------|---|------------------|
| \hat{a}_{long} | Maximale longitudinale Beschleunigung | m/s ² |
| b_{comf} | Angenehme Bremsbeschleunigung | m/s ² |
| d_0 | Minimaler Abstand zum vorausfahrenden Fahrzeug | m |
| v_0 | Gewünschte Geschwindigkeit | m/s |
| T | Minimaler zeitlicher Abstand zum vorausfahrenden Fahrzeug | s |
| β | Beschleunigungsexponent | – |

Tabelle 4.1: Die Parameter des IDM [THH00, EDK15]

Ein wichtiger Parameter in diesen Formeln ist die gewünschte Geschwindigkeit. Diese ist für beobachtete Fahrzeuge unbekannt und lässt sich nicht fest für alle Fahrzeuge an jedem Punkt der Karte festlegen, sondern muss aus der Situation des Fahrzeugs heraus geschätzt werden. Für die Ermittlung der gewünschten Geschwindigkeit stehen mehrere mögliche Parameter zur Verfügung. Zum einen ist die maximal erlaubte Geschwindigkeit \hat{v}_{leg} ein entscheidender Faktor. Diese lässt sich direkt aus der hochgenauen Planungskarte, deren Vorliegen wir als gegeben annehmen, entnehmen. Da diese Arbeit

sich hauptsächlich auf urbane Kreuzungssituationen bezieht, ist anzunehmen, dass die erlaubte Höchstgeschwindigkeit nicht (wesentlich) überschritten wird. Zum anderen können neben der maximal erlaubten Geschwindigkeit außerdem weitere Aspekte, beispielsweise der Fahrzeugdynamik und der Straßenführung, Einfluss auf die Wunschgeschwindigkeit haben. Findet eine Kurvenfahrt statt, so entsteht eine laterale Zentrifugalbeschleunigung, welche bei normalem Fahrverhalten ebenfalls durch fahrdynamische Grenzen und Wohlbefinden der Passagiere begrenzt ist [EDK15]. Hierdurch wird der neue Modellparameter der maximal angenommenen Lateralbeschleunigung \hat{a}_{lat} eingeführt, welcher die maximale an einem Punkt in einer Kurve gefahrene Geschwindigkeit \hat{v}_{kur} begrenzt. Diese lässt sich basierend auf der Krümmung $\kappa(s) = \frac{1}{r(s)}$, welche wiederum aus dem Radius r einer Kreisapproximation der Kurve an Punkt s berechnet wird, wie folgt ermitteln:

$$\hat{v}_{\text{kur}}(s) = \sqrt{\frac{\hat{a}_{\text{lat}}}{\kappa(s)}} \quad (4.3)$$

Wie man sehen kann, basiert dieser Wert ausschließlich auf Informationen aus der Planungskarte und nicht auf dynamischen Zustandsgrößen eines Fahrzeugs. Daher ist es möglich, für jeden Ort auf der Karte die gewünschte Höchstgeschwindigkeit, welche sich als $v_0 = \min(\hat{v}_{\text{leg}}, \hat{v}_{\text{kur}})$ berechnet, bereits im Voraus zu berechnen und als ergänzende Informationen zu der Karte abzuspeichern. Um zudem eine frühzeitige Geschwindigkeitsreduktion vor einer Kurvenfahrt zu modellieren, können zudem vor jeder Kurve Übergangsbereiche eingeführt werden, in welchen die gewünschte Geschwindigkeit vor einer Kurve sich bereits der gewünschten Kurvengeschwindigkeit unter Einhaltung der als angenehm empfundenen Bremsbeschleunigung b_{comf} annähert. Die weiteren Parameter für die Prädiktion wurden im Kontext dieser Arbeit als fest angenommen und aus Versuchen im Straßenverkehr basierend auf Ausgangswerten aus der Literatur (vgl. [EDK15, LKB⁺13]) bestimmt. Diese sind in Tabelle 4.2 zu finden.

Da durch das IDM ausschließlich das Fahrverhalten entlang der eigenen Fahrbahn betrachtet wird, muss davon ausgegangen werden, dass die Wahl der Fahrspur bereits getroffen wurde. Der gewählte Pfad und das gewählte Geschwindigkeitsprofil werden getrennt voneinander betrachtet. Diese Trennung ist üblich im Bereich der Trajektorienplanung und nennt sich Pfad-Geschwindigkeitszerlegung (Path-Velocity Decomposition [KZ86]). Um aus den

| Parameter | Wert | Einheit |
|-------------------------|------|----------------|
| \hat{a}_{long} | 1,2 | m/s^2 |
| b_{comf} | 0,8 | m/s^2 |
| d_0 | 2 | m |
| T | 1 | s |
| β | 4 | – |
| \hat{a}_{lat} | 2,7 | m/s^2 |

Tabelle 4.2: Die Werte der als fest angenommenen IDM Parameter.

errechneten Geschwindigkeitsänderungen konkrete Trajektorien zu errechnen, ist es notwendig, zusätzlich einen Pfad zu bestimmen, welchem die Trajektorie folgen soll. Hierzu wird im Kontext dieser Arbeit die Planungskarte verwendet. Um die Pfade zu den Geschwindigkeitsprofilen zu bestimmen, werden alle Fahrzeuge entlang der durch die Planungskarte gegebenen Mittellinien der Fahrspuren prädiziert. Da Fahrzeuge in der Realität und insbesondere bei Durchfahrten von Kreuzungssituationen nicht immer exakt in der Mitte der durch die Planungskarte gegebenen Spur fahren, führt diese Form der Prädiktion dazu, dass die prädizierten Trajektorien nicht immer konsistent mit dem aktuellen Bewegungszustand des Fahrzeugs sind. Dennoch ist dieser Ansatz ausreichend, um die Fahrzeuge für praktische Anwendungen zu prädizieren. Dies ist der Fall, da üblicherweise nicht die exakte Position des Fahrzeugs in der nahen Zukunft benötigt wird. Stattdessen sorgt die Projektion auf die Mittellinie des Streifens dafür, dass die gesamte Breite der Fahrbahn in diesem Zeitpunkt als blockiert angesehen wird. Dies ist ausreichend für die meisten praktischen Anwendungen im urbanen, fließenden Straßenverkehr, da sich hier Fahrzeuge nicht nebeneinander in derselben Fahrbahn bewegen.

4.4 Abbildung von Interaktionen im Prädiktionsmodell

Wie im vorherigen Abschnitt eingeführt, beschreibt das IDM lediglich das longitudinale Fahrverhalten in Situationen mit vorausfahrendem Fahrzeug und Kurvenfahrten mit der vorgestellten Erweiterung. In urbanen Verkehrs- und




Abbildung 4.4: Projektion von zuvor geplanten Fahrzeugen auf andere Fahrbahnen, um eine korrekte Planung des grünen Fahrzeugs umzusetzen sowie eine mögliche zugehörige topologische Sortierung.

insbesondere Kreuzungssituationen beschreiben Folgefahrten offensichtlich nur einen Bruchteil des Gesamtverhaltens aller am Verkehr teilnehmenden Fahrzeuge. Dennoch eignet sich mit einigen Modifikationen das IDM weiterhin zur Prädiktion dieses Verhaltens. Dies gelingt durch die Benutzung der durch die topologische Sortierung gegebenen Simulationsreihenfolge und das situationsbedingte und virtuelle Einfügen und Entfernen von vorausfahrenden Fahrzeugen mit geschickt gewählten Parametern.

In Abb. 4.4 ist diese Idee auf Basis des Beispiels in Abb. 3.2 illustriert. Die topologische Sortierung, welche hier simuliert werden soll, hat ergeben, dass zuerst das blaue, dann das rote Fahrzeug nacheinander simuliert werden. Da diese nicht voneinander abhängen, werden beide als frei fahrende Fahrzeuge simuliert. Dies entspricht im IDM einem vorausfahrenden Fahrzeug mit unendlicher Distanz $d = \infty$ (mit $\Delta v = 0$). Hieraus resultiert für frei fahrende Fahrzeuge die folgende Gleichung:

$$\lim_{d \rightarrow \infty} \frac{dv}{dt} = \hat{a}_{\text{long}} \left[1 - \left(\frac{v}{v_0} \right)^\beta \right] \quad (4.4)$$

Das Verhalten des grünen Fahrzeugs auf der anderen Seite muss die geplanten Trajektorien der anderen beiden Fahrzeuge berücksichtigen. Entsprechend

muss das grüne Fahrzeug warten, bis das blaue Fahrzeug den ersten kritischen Bereich durchfahren hat. Dies kann modelliert werden, indem ein stillstehendes virtuelles Fahrzeug entweder auf den kritischen Bereich selbst oder in Abstand d_0 hinter der zu dem Bereich gehörenden Haltelinie, falls vorhanden, gesetzt wird. Dieses virtuelle Fahrzeug wird in dem Zeitschritt entfernt, in welchem das blaue Fahrzeug den kritischen Bereich vollständig verlassen hat. Somit wird sichergestellt, dass das grüne Fahrzeug dies abwartet und erst anschließend eine Weiterfahrt geplant wird.

Auch die geplante Trajektorie des roten Fahrzeuges muss vom grünen Fahrzeug beachtet werden. Da es sich hier allerdings um ein Zusammenführen zweier Fahrstreifen handelt, ist hier keine gute Modellierung durch ein stillstehendes, vollständig blockierendes Fahrzeug umgesetzt. Stattdessen wird die Fahrweise des roten Fahrzeugs in die Spur des grünen Fahrzeugs projiziert. Das rote Fahrzeug wird (sobald das blaue Fahrzeug nicht mehr relevant ist) als direkt vorausfahrendes Fahrzeug modelliert. Die Position des virtuellen, roten Fahrzeugs wird hierbei so gesetzt, dass die Distanz entlang der Strecke des grünen Fahrzeugs zum kritischen Bereich dieselbe ist wie die tatsächliche Distanz entlang der Fahrstrecke des roten Fahrzeugs. Die geplante Geschwindigkeit hingegen wird direkt aus der Planung des roten Fahrzeugs entnommen, aber entlang der Strecke des grünen Fahrzeugs orientiert. Dies bedeutet, dass das virtuelle Fahrzeug mit einer der Krümmung der Kurve angepassten Geschwindigkeit modelliert wird, obwohl es sich auf einer geraden Strecke befindet. Der Effekt dieser Form von Prädiktion ist, dass die geplante Fahrt des grünen Fahrzeugs zu dem Zeitpunkt, an welchem die Zusammenführung der Spuren abgeschlossen ist, konsistent mit der Prädiktion des roten Fahrzeugs ist und übergangslos in einer echten Folgefahrt ab diesem Punkt resultiert.

Das Ergebnis dieser Prädiktionsmethode auf echten Daten des Interaction-Datensatzes [ZSW⁺19] ist in Abb. 4.5 abgebildet. Anhand dieser Abbildung ist ersichtlich, dass die Prädiktionen zu realistischen und in sich konsistenten geschätzten zukünftigen Zuständen führen. In dieser Situation wird das von unten kommende Fahrzeug entlang des Kreisverkehrs prädiziert. Dies bedeutet, dass die von rechts kommenden Fahrzeuge vor der Einfahrt in den Kreisverkehr auf Basis der braunen Trajektorie anhalten müssen. Ebenso werden Fahrzeuge durch die aktuelle Position anderer Fahrzeuge, deren Weiterfahrt ebenfalls prädiziert wurde, geplant.




Abbildung 4.5: Die Prädiktion einer Kombination von Intentionen der einzelnen Fahrzeuge mit der hier vorgestellten Methode. Als Stützpunkte sind jeweils die prädizierten Positionen in den nächsten vier Sekunden abgebildet.

Durch die explizite Modellierung der Abhängigkeiten zwischen den hier gezeigten Trajektorien und der so resultierenden gemeinsamen Prädiktion ist es zudem möglich, Aussagen über die Bedingungen von Trajektorien zu treffen. Beispielsweise kann ausgesagt werden, dass die von rechts kommenden Fahrzeuge genau dann anhalten, wenn das braune Fahrzeug dem Verlauf des Kreisverkehrs folgen wird. Solche Aussagen sind in anderen Prädiktionsformaten oft nicht möglich. Werden beispielsweise lediglich Wahrscheinlichkeitsverteilungen der zukünftigen Positionen der Fahrzeuge geschätzt, so ist es möglich, dass für ein von rechts und das von unten kommende Fahrzeug jeweils eine gewisse Wahrscheinlichkeitsmasse im relevanten kritischen Bereich liegt. Dass die Realisierungen dieser Wahrscheinlichkeiten sich gegenseitig ausschließen und gegenseitig beeinflussen, ist in vielen anderen Ansätzen nicht aus den Prädiktionsergebnissen ablesbar, auch wenn dies bei der Berechnung der Ergebnisse berücksichtigt wurde.

4.5 Validierung von Trajektorien

Die so erzeugten Trajektorien dienen in dem hier vorgestellten Ansatz als Grundlage für die Prädiktion der beobachteten Fahrzeuge. Bei der Fahrzeugprädiktion handelt es sich offensichtlich um eine äußerst zeitkritische Problemstellung. Denn sobald der nächste Zeitschritt anfängt, liegen neue Daten vor, welche von den zuvor berechneten Prädiktionen mit an Sicherheit grenzender Wahrscheinlichkeit abweichen und somit deren Relevanz für die Prädiktion des neuen Zeitschritts verringern. Dennoch ist es wünschenswert, die Berechnungsergebnisse des vorherigen Zeitschritts nicht direkt zu verwerfen. Dies ist der Fall, da, wie in Abschnitt 4.2 bereits dargelegt, in Situationen mit mehreren möglichen Interaktionen einzelne Zeitschritte nicht ausreichen, um alle realistischen Szenarien zu simulieren.

Um schnell zu identifizieren, welche Simulationen weiterhin plausibel sind und welche verworfen werden können, wird eine simple Validierungsstrategie angewendet. Der erste Schritt hierbei ist die Überprüfung, ob eine Entscheidung bei irgendeinem Fahrzeug beobachtet wurde. Dies ist der Fall, wenn ein Fahrzeug einen kritischen Bereich vor einem anderen Fahrzeug erreicht oder wenn ein Abbiegevorgang abgeschlossen wurde. In diesem Fall werden alle Simulationen, welche eine jeweils andere „Zukunft“ vorhergesagt haben, verworfen. Als Nächstes wird für jedes Fahrzeug und jede für dieses Fahrzeug durchgeführte Simulation die Abweichung der simulierten Position und Geschwindigkeit von der tatsächlich beobachteten berechnet und mit einem Schwellwert d_{val} verglichen. Bei zu starken Abweichungen wird das Fahrzeug und alle in dieser Simulation von dem Fahrzeug abhängenden Fahrzeuge erneut simuliert und nur die Prädiktionen beibehalten, die nach wie vor plausibel erscheinen.

Da die Prädiktionsergebnisse beim IDM für die ersten wenigen Zeitschritte üblicherweise nahe beieinander liegen, werden die wenigsten Simulationen zudem direkt nach einem oder zwei Zeitschritten verworfen. Somit wird durch dieses ständig durchgeführte Validierungsverfahren ermöglicht, dass eine größere Anzahl an Simulationsergebnissen in den einzelnen Zeitschritten zur Verfügung steht, als tatsächlich in diesem berechnet werden können. Die so errechneten Ergebnisse können dann in den nächsten Schritten benutzt werden, um der Intentionsschätzung als Informationsbasis über das vermutete Verhal-

ten der betrachteten Fahrzeuge in einer großen Anzahl an unterschiedlichen Zukunftsszenarien zu dienen.

5 Intentionsschätzung

Dieses Kapitel fokussiert sich auf den Ansatz zur Intentionsschätzung anderer Fahrzeuge, welcher im Rahmen dieser Arbeit entwickelt wurde. Dieser Ansatz baut auf den Ergebnissen der vorherigen beiden Kapitel auf. Die Ergebnisse aus Kapitel 3 werden benutzt, um die Abhängigkeiten zwischen verschiedenen Fahrzeugen abzubilden und den Zustandsraum des Modells aufzubauen, während die Ergebnisse aus Kapitel 4 die Grundlage für das Beobachtungsmodell bilden.

Das Kapitel beginnt zunächst mit einer Einbettung dieses Parts in den Gesamtkontext der Arbeit sowie einer Einführung des verwendeten Grundmodells in Abschnitt 5.1. Abschnitt 5.2 erklärt den entsprechenden Algorithmus, welcher für die Inferenz in dem Modell verwendet wird. Anschließend wird in Abschnitt 5.3 das auf den Ergebnissen aus Kapitel 4 beruhende Beobachtungsmodell eingeführt. Die Ergebnisse aus Kapitel 3 finden in Abschnitt 5.4 im Zustandsraum Anwendung. Die Erweiterungen des Modells, welche sich aus der Interaktivität der Situationen ergeben, schließen in den Abschnitten 5.5 und 5.6 das Kapitel ab.

5.1 Intentionsschätzung mit Hidden Markov Models

Das zukünftige Verhalten eines Fahrzeuges mit einem menschlichen Fahrer ist das direkte Resultat der Intention des Fahrers. Nur wenn die Intention des Fahrers implizit oder explizit korrekt erkannt wird, ist es möglich vorherzusagen, ob ein Fahrzeug abbremsen, beschleunigen, abbiegen oder ein anderes mögliches Manöver wählen wird. Als außenstehender Betrachter ist es allerdings nur möglich, das bisherige Verhalten des Fahrzeuges, nicht jedoch die Intention des Fahrers direkt zu beobachten. Man kann daher die Intention des

Fahrers als nicht beobachtbaren Zustand bezeichnen, während das bisherige Verhalten des Fahrzeugs beobachtbar ist. Dennoch hängt die Wahrscheinlichkeit, eine bestimmte Beobachtung des Verhaltens zu machen, direkt von der unbeobachtbaren Größe der Intention ab.




Abbildung 5.1: Hervorgehoben sind diejenigen Aspekte, welche im Kontext dieses Kapitels im Vordergrund stehen. In Grün hervorgehoben sind die internen Zustände s_i des jeweiligen Fahrzeugs i , die es zu schätzen gilt. Basierend auf denen wird in Gelb eine Aktion c_i ausgeführt, welche als Emission im Beobachtungsmodell abgebildet wird. Rot markiert sind Beeinflussungen durch andere Fahrzeuge, die sich durch Beobachtungen o_i auf den internen Zustand auswirken und in Abschnitt 5.5 modelliert werden.

Dies wird auch in der zuvor eingeführten und in Abb. 5.1 noch einmal dargestellten Modellierung des Datenflusses in der menschlichen Entscheidungsfindung in Form eines POSG deutlich. Einem außenstehenden Betrachter stehen nur die Informationen zur Verfügung, welche durch Beobachtung der Aktionen, die der Fahrer basierend auf seiner Intention wählt, gewonnen werden. Um Rückschlüsse auf die zugrundeliegenden Intentionen eines Fahrers ziehen zu können, müssen die Zusammenhänge zwischen dem Beobachtbaren und dem Unbeobachtbaren mathematisch modelliert werden.

Diese Trennung zwischen beobachtbaren und nicht-beobachtbaren Größen lässt sich sehr gut in sogenannten Hidden Markov Modellen (HMMs) abbilden. Hierbei handelt es sich um einen Spezialfall eines dynamischen Bayes'schen Netzes, bei welchem davon ausgegangen wird, dass die Markov-Annahme gilt. Die Markov-Annahme setzt sich aus zwei Eigenschaften zusammen, welche als gegeben angenommen werden müssen. Zum einen bedeutet dies in dem hier vorgestellten Anwendungsfall, dass die Wahrscheinlichkeit, dass sich die In-

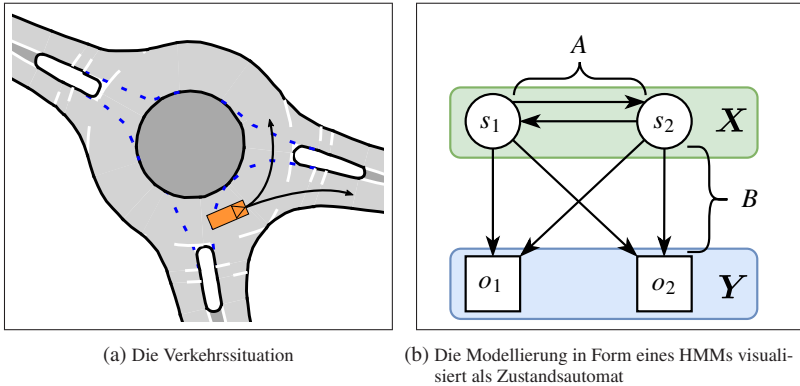


Abbildung 5.2: Die Modellierung einer einfachen Verkehrssituation mit zwei möglichen Intentionen sowie zwei mögliche beobachtbare Handlungsweisen.

tention des Fahrers ändert, ausschließlich von der aktuellen Intention des Fahrzeugfahrers abhängt. Zum anderen darf die Wahrscheinlichkeit, ein bestimmtes Verhalten des Fahrers zu beobachten, ebenfalls nur von der aktuellen Intention abhängen. Auf diese beiden Annahmen wird in den folgenden Abschnitten beim Einbringen der Inter-Fahrzeugabhängigkeiten und dem Einführen des nicht-stationären Hidden Markov-Models (NSHMM) nochmal eingegangen werden. Für den Moment werden sie jedoch nicht hinterfragt.

In Abb. 5.2 ist ein Beispiel für eine der einfachsten Entscheidungssituationen im Straßenverkehr illustriert. Das Fahrzeug hat genau zwei Möglichkeiten, sich verkehrsregelgerecht zu verhalten. Entweder es bleibt im Kreisverkehr, oder es verlässt diesen, indem es rechts abbiegt. Welche dieser Möglichkeiten gewählt wird, hängt von der Intention des Fahrers ab. In diesem Fall handelt es sich um eine Menge von zwei möglichen verborgenen Zuständen $S = \{s_1, s_2\}$, welche jeweils die Intentionen „dem Kreisverkehr folgen“ und „den Kreisverkehr verlassen“ repräsentieren. Diese Zustände beschreiben die möglichen Werte der Zufallsvariablen X . Im Folgenden wird angenommen, dass es im Allgemeinen $n \in \mathbb{N}$ mögliche Zustände s_1, \dots, s_n für X gibt. In dem hier angeführten Beispiel ist somit $n = 2$. Zwar sind Erweiterungen von HMMs auf kontinuierliche Zustandsmengen möglich, im Kontext dieser Arbeit, werden diese jedoch nicht betrachtet. Dies ist darin begründet, dass es sich bei den Intentionen, wie sie hier definiert sind, stets um diskrete Entscheidungen, wie „links fahren“

oder „abbiegen“ handelt. Neben der Zufallsvariablen X beinhaltet ein HMM außerdem eine Zufallsvariable Y , welche die Beobachtung (oder Emission) beschreibt. In klassischen HMMs handelt sich hier ebenfalls um eine Zufallsvariable mit einer endlichen Menge an möglichen Werten O . Im Folgenden wird allerdings mit einem komplexeren Emissionsmodell gearbeitet werden und daher an dieser Stelle keine Einschränkungen bezüglich der Dimensionalität und Kardinalität der Menge der möglichen Werte O für Y festgelegt. In dem gegebenen Beispiel könnte man stark vereinfachend zwei mögliche Beobachtungen definieren, die jeweils den Beobachtungen der Umsetzung der jeweiligen Intentionen entsprechen. Diese beiden Zufallsvariablen bilden so zwei stochastische Prozesse, welche Teil des HMMs sind. Wenn X_t und Y_t die Werte der jeweiligen Zufallsvariablen zum Zeitpunkt t beschreiben, können nun die vorher bereits in Worte gefassten Markov-Annahmen ausformuliert werden zu:

$$P(X_t = s | s_{0:t-1}) = P(X_t = s | X_{t-1} = s_{t-1}) \quad (5.1)$$

$$P(Y_t = o | s_{0:t}, o_{0:t-1}) = P(Y_t = o | X_t = s_t) \quad (5.2)$$

Wobei wir uns jeweils hier und im Folgenden der Kurzschreibweisen bedienen: $s_{0:t} := X_0 = s_0, \dots, X_t = s_t$ und $o_{0:t} := Y_0 = o_0, \dots, Y_t = o_t$.

Das vollständige HMM wird nun beschrieben durch:

- Die Menge S der möglichen Werte für die Zustandsvariable X mit $n = |S|$.
- Die Menge O der möglichen Werte der Beobachtungen für die Emissionsvariable Y .
- Die Wahrscheinlichkeiten für die Übergänge zwischen den möglichen Zuständen. Diese werden üblicherweise für einen diskreten Zustandsraum durch eine Zustandsübergangsmatrix $A \in \mathbb{R}^{n \times n} = \{a_{i,j}\} (i, j \in \{1, \dots, n\})$ repräsentiert mit:

$$a_{i,j} := P(X_t = s_j | X_{t-1} = s_i) \quad \forall i, j \in \{1, \dots, n\} \quad (5.3)$$

Im Folgenden wird hierbei die Notation für zeitlich direkt aufeinander folgende Zustände verkürzt zu:

$$P(s_j | s_i) := P(X_t = s_j | X_{t-1} = s_i) \quad (5.4)$$

- Ein Beobachtungsmodell $B = \{b_i\}$, welches für jede mögliche Beobachtung $o \in O$ und einen gegebenen Zustand s_i beschreibt, wie wahrscheinlich es ist, diese Beobachtung in diesem Zustand zu machen:

$$b_i(o) := P(Y = o | X = s_i) \quad \forall i \in \{1, \dots, n\}, o \in O \quad (5.5)$$

mit alternativer Notation:

$$P(o | s_i) := P(Y = o | X = s_i) \quad (5.6)$$

- Eine Initialverteilung $\pi \in \mathbb{R}^n$, welche für jeden möglichen Zustand die Wahrscheinlichkeit angibt, in ihm zu starten:

$$\pi_i := P(X_0 = s_i) \quad \forall i \in \{1, \dots, n\} \quad (5.7)$$

Das vollständige HMM ist somit gegeben durch das Tupel dieser Modellparameter $\lambda := (S, O, A, B, \pi)$. Außerdem führen wir noch die Kurzschreibweise $P(s | o_{0:t}) := P(X_t = s | o_{0:t})$ ein für die bedingte Wahrscheinlichkeit, sich in einem bestimmten Zustand zu befinden, nachdem eine Menge an Beobachtungen gemacht wurde.

5.2 Forward-Algorithmus

Dieses Modell wurde ausgewählt, um Information über die verborgenen Intentionen des Fahrers zu inferieren. Bei einem HMM kann dies durch den sogenannten Forward-Algorithmus umgesetzt werden. Dieser berechnet, gegeben einem HMM und einer Abfolge von Beobachtungen o_0, \dots, o_t , die Wahrscheinlichkeit, dass genau diese Beobachtungen erfolgen. Namensgebend sind hier die sogenannten Forward-Variablen α , welche iterativ als Zwischenergebnis berechnet werden. Diese Variablen beschreiben jeweils die gemeinsame Wahrscheinlichkeit für die Beobachtungssequenz bis zum Zeitpunkt t und dass sich das System zum Zeitpunkt t in einem bestimmten verborgenen Zustand befindet [BFA22]:

$$\alpha_t(s) := P(X_t = s, o_{0:t}) \quad s \in S, o \in O \quad (5.8)$$

Diese können rekursiv berechnet werden über die Formel:

$$\alpha_t(s) = P(o_t|s) \cdot \sum_{s_i \in S} P(s|s_i) \cdot \alpha_{t-1}(s_i) \quad (5.9)$$

Wobei die Wahrscheinlichkeit für den Zustandsübergang $P(s|s_i)$ durch A und die Beobachtungswahrscheinlichkeit $P(o|s)$ durch B gegeben ist. Basierend auf der Definition von bedingten Wahrscheinlichkeiten ergibt sich nun mit $\alpha_t = \sum_{s \in S} \alpha_t(s)$:

$$P(s|o_{0:t}) = \frac{P(X_t = s, o_{0:t})}{P(o_{0:t})} = \frac{\alpha_t(s)}{\alpha_t} \quad (5.10)$$

Somit kann basierend auf den Teilergebnissen des Forward-Algorithmus die Wahrscheinlichkeit für alle verborgenen Zustände gegeben einer Sequenz von Beobachtungen berechnet werden. Diese Form des Forward-Algorithmus hat allerdings ein paar praktische Probleme. Die Forward-Variablen nehmen in der Regel bereits nach wenigen Schritten sehr kleine Werte an, welche zu Ungenauigkeiten oder einem Underflow in der Gleitkommazahl-Repräsentation der Variablen führen können. Stattdessen kann man, sofern einen ausschließlich das Ergebnis der Gleichung (5.10) interessiert, direkt auf diesen bedingten Wahrscheinlichkeiten rechnen. Hierbei kann man sich zunutze machen, dass basierend auf Gleichung (5.10) $P(s|o_{0:t}) = c_t \cdot \alpha_t(s)$ gilt, wobei $c_t = \frac{1}{P(o_{0:t})}$ für alle Zustände s im selben Zeitschritt konstant ist. Mit dieser Information lässt sich Gleichung (5.10) durch Einsetzen von Gleichung (5.9) umschreiben zu:

$$P(s|o_{0:t}) = c_t \cdot \alpha_t(s) = c_t \cdot P(o_t|s) \cdot \sum_{s_i \in S} P(s|s_i) \cdot \alpha_{t-1}(s_i) \quad (5.11)$$

Da $\alpha_{t-1}(s_i) = \frac{P(s_i|o_{0:t-1})}{c_{t-1}}$, ergibt sich:

$$P(s|o_{0:t}) = c_t \cdot P(o_t|s) \cdot \sum_{s_i \in S} P(s|s_i) \cdot \frac{P(s_i|o_{0:t-1})}{c_{t-1}} \quad (5.12)$$

In dieser Gleichung lässt sich $\frac{1}{c_{t-1}}$ aus der Summe ziehen und es resultiert das Äquivalent zu Gleichung (5.9) mit einem Vorfaktor $\frac{c_t}{c_{t-1}}$. Zuletzt kann zunutze

gemacht werden, dass $\sum_{s_i \in S} P(s_i | o_{0:t}) = 1$ für alle Zeitschritte t . Somit kann dieser Vorfaktor zunächst ignoriert werden. Stattdessen berechnet man

$$P(s | o_{0:t}) \cdot \frac{c_{t-1}}{c_t} = P(o_t | s) \cdot \sum_{s_i \in S} P(s | s_i) \cdot P(s_i | o_{0:t-1}) \quad (5.13)$$

und eliminiert anschließend den Vorfaktor durch Normierung der so erhaltenen Ergebnisse auf die Summe 1. Dadurch wird außerdem verhindert, dass die mit wachsendem t verschwindend kleine Wahrscheinlichkeit $P(o_{0:t})$ explizit berechnet werden muss, was für die Berechnung von $P(s | o_{0:t})$ aus $\alpha_t(s)$ notwendig wäre. Außerdem erleichtert diese Formulierung das Rechnen im kontinuierlichen Beobachtungsraum, bei dem die Wahrscheinlichkeit für einzelne Beobachtungen 0 ist.

5.3 Beobachtungsmodell

Um die in Abschnitt 5.2 beschriebene Form des Forward-Algorithmus anwenden zu können, werden die Zustandsübergangsmatrix A und das Beobachtungsmodell B benötigt. Die Modellierung der möglichen Beobachtungen und das Konstruieren des Beobachtungsmodells sind in diesem Anwendungsfall allerdings relativ kompliziert. Während sich die Beobachtungen theoretisch genauso wie die Intentionen des Autofahrers in zwei Verhaltensmuster aufteilen lassen, die jeweils dem Umsetzen einer der beiden möglichen Intentionen entsprechen, sind diese in der Praxis nicht ohne Weiteres zu beobachten. Direkt beobachtbar ist nur eine Menge von Eigenschaften des Fahrzeuges wie die aktuelle Position, Geschwindigkeit und Orientierung, welche im Kontext eines selbstfahrenden Fahrzeugs über Sensoren automatisch erfasst werden können. Daher besteht in diesem Anwendungsfall jede Beobachtung o aus einem Vektor von m beobachtbaren Größen und die Menge aller möglichen Beobachtungen hat die Form $O \subseteq \mathbb{R}^m$, $m \in \mathbb{N}$. Während sich im Fall einer diskreten, endlichen Menge an möglichen Beobachtungen das Beobachtungsmodell ähnlich wie die Zustandsübergangsmatrix durch eine Matrix beschreiben ließe, ist dies auf den Beobachtungsvektor mit kontinuierlichem Wertebereich nicht übertragbar. Um das Beobachtungsmodell zu konstruieren, wird stattdessen zunächst eine Funktion $f : S \rightarrow O$ gesucht, welche eine Relation zwischen den möglichen Intentionen und den beobachtbaren Größen herstellt.

Da eine solche Funktion eine Fahrzeugintention auf eine Menge von Größen abbildet, die den dynamischen Zustand des Fahrzeuges beschreiben, entspricht das Finden einer solchen Funktion dem Vorgang des Planens von Fahrzeugtrajektorien. Gegeben die Verkehrssituation und eine Zielvorgabe, welche in diesem Kontext mit der zu schätzenden Intention gleichgesetzt werden kann, generiert ein Trajektorienplaner eine Abfolge von Fahrzeugzuständen, welche die gewünschte Intention verwirklicht, so dies möglich ist. Indem ein Trajektorienplaner benutzt wird, können somit für jeden Zeitschritt und für jede Intention mögliche Beobachtungen bestimmt werden, die genau den beobachtbaren Größen entsprechen.

Ein Algorithmus für die Trajektorienplanung liefert jedoch niemals exakt dasselbe Ergebnis, welches aus dem Verhalten des menschlichen Fahrers entsteht. Daher ist es notwendig, sich von der Idee zu entfernen, dass es nur genau zwei mögliche Beobachtungen gibt. Es ist, wenn man von Diskretisierungen im Beobachtungsvorgang absieht, stattdessen eine unendliche Menge an Beobachtungen möglich. Ein Beobachtungsmodell, wie in Gleichung (5.5) beschrieben, würde im kontinuierlichen Fall üblicherweise für alle einzelnen Beobachtungen die Wahrscheinlichkeit 0 liefern, was in Gleichung (5.10) beim klassischen Forward-Algorithmus außerdem zu einem Teilen durch 0 führen würde. Um dies zu umgehen, wird an dieser Stelle nicht die tatsächliche Wahrscheinlichkeit der Beobachtungen betrachtet, sondern es wird sich auf die Wahrscheinlichkeiten der Beobachtungen für jeden Zustand relativ zu den anderen Zuständen konzentriert. Anstatt also mit infinitesimalen Wahrscheinlichkeiten zu rechnen, wird anhand der durchgeführten Beobachtungen entschieden, ob diese eher der geplanten Trajektorie für den ersten oder denen für den zweiten Fall entsprechen, um ein Beobachtungsmodell aufstellen zu können. Dies entspricht einer Uminterpretation der zuvor diskreten Beobachtungswahrscheinlichkeiten als Wahrscheinlichkeitsdichtefunktion (WDF), da diese ebenfalls Auskunft über relative Wahrscheinlichkeiten ermöglicht. Wenn man nun die Intention als Parameter einer solchen WDF modelliert, berechnet man somit für eine feste Beobachtung die Likelihood, dass die jeweilige Intention diese verursachen kann.

Es ist allerdings nicht zwangsläufig notwendig, eine explizite und parametrisierte WDF über den Beobachtungsvektor als Beobachtungsmodell aufzustellen. Stattdessen wird vom Beobachtungsmodell lediglich gefordert, dass es Aus-

kunft über die relative Wahrscheinlichkeit im Hinblick auf andere Zustände gibt. Formell wird erwartet, dass:

$$b_i(o) > b_j(o) \Rightarrow P(o|s_i) > P(o|s_j) \forall i, j \in \{0, \dots, n\}, o \in O \quad (5.14)$$

Die Normierungen $b_i(o) \in [0, 1]$, $\sum_{b_i} b_i(o) = 1$ sind an dieser Stelle streng genommen nicht notwendig, da diese in der hier vorgestellte Variante des Forward-Algorithmus automatisch geschehen. Dennoch werden sie im Folgenden ebenfalls als gegeben angenommen, um die Ähnlichkeit zu klassischen WDFs zu wahren.

Um ein solches Beobachtungsmodell aus dem Ergebnis des IDM-basierten Planungsalgorithmus, welcher in Kapitel 4 eingeführt wurde, zu erhalten, gibt es mehrere Optionen, von denen zwei ursprünglich von Liebner et al. [LKB⁺13] nicht im Kontext eines HMMs, sondern als Realisierung eines einfachen Bayes'schen Netzes modelliert wurden und welche hier Anwendung finden. Maßgeblich ist hier die Unterscheidung zwischen Szenarien, welche bereits vollständig in vergangenen Zeitschritten simuliert wurden, und denen, für welche keine Simulation vorliegt. Liegt keine Simulation für die betrachteten Intentionen vor, so kann dennoch effizient für jede dieser Intentionen ein einziger Schritt der IDM-Planung durchgeführt werden und anschließend das Ergebnis dessen mit der Beobachtung verglichen werden. In diesem Fall vergleicht man eine beobachtete Geschwindigkeitsänderung mit der geplanten Geschwindigkeitsänderung des IDM-Ergebnisses. Hierfür kann unter Annahme, dass gegeben das Ergebnis eines IDM-Planungsschrittes a_{IDM} für eine Intention s die tatsächlich durchgeführten Geschwindigkeitsänderungen a eines menschlichen Fahrers mit derselben Intention normalverteilt mit Standardabweichung σ_a um den geplanten Wert liegen, folgende WDF f_a aufgestellt werden.

$$f_{\text{vgl}}(a|s) = \frac{1}{\sigma_a \sqrt{2\pi}} \exp \left[-\frac{1}{2} \left(\frac{a - a_{\text{IDM}}(s)}{\sigma_a} \right)^2 \right] \quad (5.15)$$

Um dieses Ergebnis robuster gegenüber Messrauschen zu machen, welches insbesondere bei der Beobachtung von Geschwindigkeitsänderungen erheblich sein kann, wird, falls mehrere Zeitschritte bereits beobachtet wurden, statt der direkt beobachteten Geschwindigkeitsänderung der Durchschnitt der beobachteten Geschwindigkeitsänderungen in den letzten Zeitschritten verwendet.

Dem gegenüber stehen simulationsbasierte Ansätze, welche sich zunutze machen, dass durch einen Planungsalgorithmus Geschwindigkeitsänderungen über mehrere Zeitschritte basierend auf dem Ergebnis einer Simulation des weiteren Verlaufs berechnet werden können. Statt nur ein einzelnes Ergebnis – im vorherigen Ansatz das für den aktuellen Zeitschritt – zu verwenden, wird hier das Ergebnis einer Simulation über mehrere Zeitschritte, welche in der Vergangenheit für den aktuellen Zeitpunkt durchgeführt wurde, benutzt. Dies hat den Vorteil, dass die Schätzung robuster gegenüber Mess-ungenauigkeiten und von der Realität abweichenden Annahmen über Modellparameter ist. Generell ist hierbei eine große Menge an Methoden zum Vergleich der Beobachtung mit den simulierten Trajektorien denkbar. Diese lassen sich beispielsweise aus den Metriken, welche in [QHT⁺17] vorgestellt wurden, ableiten. In [LKB⁺13] wurden hierfür lediglich die erwartete Position und Geschwindigkeit, welche für den aktuellen Zeitschritt in einer T_s zurückliegenden Prädiktion errechnet wurde, verwendet. Hierbei handelt es sich zwar auch um Einzelwerte, diese basieren jedoch auf einer Akkumulation der Planungsergebnisse mehrerer Zeitschritte. Unter Annahme der statistischen Unabhängigkeit sowie einer Normalverteilung mit den Standardabweichungen σ_d und σ_v für die geplante Position $d_{\text{IDM}}(s)$ bzw. Geschwindigkeit $v_{\text{IDM}}(s)$ für Intention s ergibt sich somit die folgende WDF:

$$f_{\text{sim}}(d, v|s) = \frac{1}{2\sigma_d\sigma_v\pi} \exp\left(-\frac{1}{2}e^2\right) \quad (5.16)$$

mit

$$e = \sqrt{\left(\frac{d - d_{\text{IDM}}(s)}{\sigma_d}\right)^2 + \left(\frac{v - v_{\text{IDM}}(s)}{\sigma_v}\right)^2} \quad (5.17)$$

Die Annahme der statistischen Unabhängigkeit dieser Größen wurde an dieser Stelle aus [LKB⁺13] übernommen. Hier könnte allerdings auch durch Einführung einer Kovarianzmatrix die positive Korrelation zwischen diesen Größen ergänzt werden.

Generell ist der Vorteil von den simulationsbasierten Modellen, dass nicht nur einzelne Prädiktionswerte betrachtet werden müssen. Hat man die entsprechenden Intentionen bereits bis zum aktuellen Zeitpunkt simuliert, so bietet sich eine Reihe unterschiedlicher Methoden an, um die tatsächlich beobachtete Trajektorie der letzten Zeitschritte mit den prädierten zu vergleichen. In vielen Fällen liegt jedoch keine simulierte Trajektorie für die entsprechenden

Hypothesen vor, wie sich aus den kombinatorischen Überlegungen in Kapitel 4 ableiten lässt.

In beiden Methoden hat lediglich longitudinales Fahrverhalten Einfluss auf den Verlauf der Berechnungen. In realen Situationen können jedoch auch das Lenkverhalten und andere Informationsquellen, wie der Fahrtrichtungsanzeiger, weiteren Aufschluss über den intendierten Pfad liefern. Daher ist es sinnvoll, die Ergebnisse um eine weitere Berechnung zu erweitern, welche die Benutzung solcher Informationen ermöglicht. Hierfür wird angenommen, dass ein Klassifikator existiert, welcher beispielsweise auf Basis einer Erkennung des Fahrtrichtungsanzeigers eines Fahrzeuges eine Wahrscheinlichkeit für die unterschiedlichen Pfade ausgibt. Mathematisch bedeutet dies, dass ein Pfadklassifikator benutzt wird, welcher die Wahrscheinlichkeit $P(p|o)$ eines Pfades p gegeben der Beobachtung o ausgibt. Dieser Klassifikator findet genau dann Anwendung, wenn die zu schätzenden Intentionen sich auf kritische Bereiche mit Entscheidungspunkten beziehen. Um diesen Klassifikator mit den zuvor eingeführten WDF zu kombinieren, wird hier wie folgt vorgegangen. Zunächst wird von $P(p|o)$ auf $P(o|p)$ geschlossen. Nach dem Satz von Bayes kann dies umgesetzt werden durch $P(o|p) = \frac{P(p|o) \cdot P(o)}{P(p)}$. Ist $P(p)$ beispielsweise aus einem Datensatz ähnlicher Verkehrssituationen bekannt, so kann dies direkt benutzt werden, andernfalls wird hier eine Gleichverteilung über alle möglichen Pfade angenommen. $P(o)$ auf der anderen Seite ist konstant für alle möglichen Pfade und spielt somit für die Berechnung der relativen Wahrscheinlichkeiten unterschiedlicher Pfade keine Rolle. Da hier ebenfalls nur die relativen Wahrscheinlichkeiten der Beobachtungen zueinander für die einzelnen Pfade zählen, wird $\frac{P(o)}{P(p)}$ bei Annahme der Gleichverteilung von p auf 1 gesetzt, andernfalls mit festem $P(o)$ berechnet und anschließend auf $\sum p P(o|p) = 1$ normiert. Somit hat die WDF einen Bildbereich von $(0, \frac{1}{\sigma_a \sqrt{2\pi}}]$ bzw. $(0, \frac{1}{2\sigma_d \sigma_v \pi}]$, während der Pfadklassifikator Wahrscheinlichkeiten im Wertebereich $[0, 1]$ annehmen kann. Kombiniert werden diese beiden Klassifikatoren nun durch ein gewichtetes Ensemble, wobei der Pfadklassifikator jeder Intention denselben Anteil an der Wahrscheinlichkeit des dazugehörigen Pfades zuteilt. Die Gewichte des Ensembles werden nun für den Pfadklassifikator auf 1 gesetzt und für die WDF auf $\sigma_a \sqrt{2\pi}$ bzw. $2\sigma_d \sigma_v \pi$. Somit werden die möglichen Wertebereiche für beide Wahrscheinlichkeitsschätzungen einander angeglichen und es wird verhindert, dass der Pfadklassifikator die WDF dominiert.

5.4 Zustandsraum

Neben dem Beobachtungsmodell wird ebenfalls eine Definition des Zustandsraums sowie der Übergangs- und Initialwahrscheinlichkeiten S , A und π benötigt, um ein vollständiges HMM zu definieren. Anhand des Beispiels in Abb. 5.2 war bereits ersichtlich, dass sich der Zustandsraum zumindest teilweise aus der Straßentopologie ableiten lässt. In dem Beispiel wurden zwei mögliche Intentionen durch eine Entscheidung zwischen zwei möglichen Pfaden induziert. Die topologische Untersuchung der Karte, die durchgeführt wird, um die Orte zu finden, an welchen mehrere Möglichkeiten, aus denen sich die Intentionen herleiten, existieren, entspricht der Suche nach Entscheidungspunkten, wie sie in Abschnitt 3.3 eingeführt wurden. Für jedes Fahrzeug, was sich auf einen solchen Bereich zubewegt und diesen innerhalb eines festgelegten Prädiktionshorizonts voraussichtlich erreicht, wird ein HMM initialisiert, welches die unterschiedlichen Entscheidungen in Form von Intentionen im Zustandsraum beinhaltet.




Abbildung 5.3: Eine Verkehrssituation mit zwei in Konflikt stehenden Fahrzeugen. Die möglichen Pfade jedes Fahrzeugs sind in Form von Pfeilen eingezeichnet, die jeweils relevanten kritischen Bereiche in blau unterlegt.

Dasselbe gilt ebenso für Konfliktbereiche, falls es weitere Fahrzeuge gibt, die auf denselben Konfliktbereich zusteuern. In Abb. 5.3 sieht man dieselbe Verkehrssituation wie im vorherigen Beispiel mit der Abweichung, dass dieses

Mal ein weiteres, potenziell in Konflikt stehendes Fahrzeug an der Szene teilmimmt. Möchte man das Verhalten des gelben Fahrzeugs mit einem HMM prädisieren, so initialisiert man ein HMM für die Konfliktsituation im roten Konfliktbereich. Das gelbe Fahrzeug hat hier die Möglichkeiten, entweder direkt in den Kreisverkehr einzufahren oder zunächst zu verzögern und somit das zuvor betrachtete, orange Fahrzeug passieren zu lassen. Beide Möglichkeiten werden als Zustände im HMM für das gelbe Fahrzeug initialisiert.




Abbildung 5.4: Der zu Abb. 5.3 gehörige Abhängigkeitsgraph auf Pfadenebene mit seinen möglichen Realisierungen. Die möglichen Intentionen für beide Fahrzeuge ergeben sich direkt hieraus.

Formell wird die Menge an Zuständen direkt aus dem zugehörigen Abhängigkeitsgraphen, welcher in Abb. 5.4 dargestellt ist, berechnet. Für jedes Fahrzeug wird betrachtet, welche Abhängigkeiten es zu anderen Fahrzeugen (bzw. zu deren Pfaden) besitzt. Für jede dieser Abhängigkeiten wird jeweils eine Intention dafür initialisiert, dass sie in einer topologischen Sortierung der Knoten vorwärts oder rückwärts gerichtet ist. In dem hier abgebildeten Beispiel heißt dies, dass für beide Fahrzeuge jeweils eine Intention initialisiert wird, welche bedeutet, dass zuerst oder als zweites gefahren wird. Außerdem wird für jeden möglichen Pfad mindestens eine Intention initialisiert. Dies bedeutet, dass für das orange Fahrzeug eine dritte Intention initialisiert wird, für das gelbe Fahrzeug hingegen nicht. Für das gelbe Fahrzeug ist die Intention, zuerst zu fahren, gleichbedeutend mit der Intention, durch Abbiegen des anderen Fahrzeugs als einziges durch den kritischen Bereich zu fahren, da in beiden Fällen keine Abhängigkeit zu dem Verhalten des orangenen Fahrzeugs besteht. Somit ergeben sich in diesem Beispiel für das orange Fahrzeug drei interne Zustände, für das gelbe Fahrzeug hingegen nur zwei.

Es ist an dieser Stelle anzumerken, dass im Falle von Situationen mit mehr als zwei Fahrzeugen diese Art der Intentionskonstruktion dazu führt, dass nicht für jede mögliche topologische Sortierung für jedes Fahrzeug eine eigene Intention initialisiert wird. Es werden stattdessen pro Fahrzeug lediglich die nächsten Fahrzeuge in der topologischen Sortierung betrachtet, zu denen eine Abhängigkeit besteht. Für jedes Fahrzeug wird nur betrachtet, welches das letzte Fahrzeug ist, von dem es beeinflusst wird, und welche Pfade ausgewählt werden. Dies wird dadurch begründet, dass falls ein Fahrzeug lang genug verzögert, um mehrere andere Fahrzeuge vorher passieren zu lassen, das Verhalten identisch ist zu dem Verhalten, dass das Fahrzeug lediglich für das letzte Fahrzeug verzögern möchte. In welcher Reihenfolge die Fahrzeuge davor den kritischen Bereich passieren, ist für das Verhalten irrelevant.

Zur Bestimmung der Anfangs- und Zustandsübergangswahrscheinlichkeiten π und A in einem HMM werden üblicherweise Algorithmen herangezogen, welche diese basierend auf einem Beispieldatensatz nach der Maximum-Likelihood-Methode berechnen. Vermutlich am weitesten verbreitet ist hier der Baum-Welch-Algorithmus, welcher als Teil des Forward-Backward Algorithmus auch die bereits eingeführten Forward-Variablen α benutzt, um diejenigen Werte für π , A und B zu bestimmen, welche die Daten des Datensatzes am besten abbilden. Da im Folgenden allerdings ein Ansatz eingeführt wird, der diese Wahrscheinlichkeiten manipuliert, ist ein solcher Ansatz hier nicht zur Anwendung gekommen. Stattdessen werden feste Werte benutzt, welche als Modellparameter zu betrachten sind. Im Falle des orangen Fahrzeugs werden beide möglichen Wahrscheinlichkeiten zunächst als gleich wahrscheinlich angenommen. Hier wäre es möglich zu erkennen, dass dieses Fahrzeug höchstwahrscheinlich den Kreisverkehr verlassen wird, da es andernfalls zurück in die Richtung fahren würde, aus der es basierend auf der Fahrzeugorientierung vermutlich gekommen ist. Diese Form der Abschätzung ist jedoch äußerst situationsbedingt und lässt sich kaum verallgemeinern. Daher wird im Kontext dieser Arbeit von einer solchen Annahme abgesehen und versucht, ein Modell zu konstruieren, welches auch für andere interaktive Situationen angewandt werden kann. Stattdessen wird hier lediglich durch eine oberflächliche Analyse die Menge der möglichen Pfade bestimmt und eine Gleichverteilung über diese angenommen.

Für das gelbe Fahrzeug hingegen muss entschieden werden, ob es verzögert und das andere Fahrzeug, welches Vorrang hat, zuerst fahren lässt. In Ab-

schnitt 3.6 und Abschnitt 3.7 wurde bereits eine Funktion g eingeführt, welche benutzt wird, um die Wahrscheinlichkeit abzuschätzen, ob ein Fahrzeugpfad von einem anderen Fahrzeugpfad abhängt, gegeben, dass sich beide Fahrzeuge für den entsprechenden Pfad entscheiden. Diese Funktion kann direkt benutzt werden, um die initiale Wahrscheinlichkeitsverteilung über die Zustände π für dieses Fahrzeug zu bestimmen. Hierfür wird zunächst eine Gleichverteilung über alle Routing-Entscheidungen angenommen und die für die entsprechende Route anfallenden Wahrscheinlichkeiten mit den aus g erhaltenen Wahrscheinlichkeiten für die jeweiligen Intentionen multipliziert (und normiert, im Falle multipler Abhängigkeiten). Sei in dem gegebenen Beispiel angenommen, dass g basierend auf den Vorfahrtsregeln und den Formeln aus Abschnitt 3.7 eine Wahrscheinlichkeit von 0,7 dafür ausgibt, dass der linke Pfad des orangen Fahrzeugs vom gelben Pfad abhängt. Somit ergibt sich für das orange Fahrzeug eine Verteilung von 0,5, den Kreisverkehr zu verlassen, und 0,35 bzw. 0,15 dafür, im Kreisverkehr zu bleiben und zuerst bzw. als Zweites zu fahren. Da das gelbe Fahrzeug eine Pfadwahrscheinlichkeit von 1 für den voraus liegenden Pfad aufweist, ergibt sich für dieses Fahrzeug eine initiale Verteilung von 0,3 zu 0,7.

Des Weiteren wird hier angenommen, dass ein menschlicher Fahrer eines Fahrzeuges seine Intention nur selten, zumindest im Vergleich zur Frequenz, mit der die Intentionsschätzung stattfindet, ändert. Hat ein Fahrer vor, einer bestimmten Route zu folgen, oder vor/nach einem anderen Fahrzeug zu fahren, wird er diese Entscheidung nicht mehrfach pro Sekunde ändern. Deswegen wird die Zustandsübergangsmatrix A mit einer hohen Wahrscheinlichkeit a_{bias} dafür, im selben Zustand zu bleiben, initialisiert. Dieser Wert ist ein Modellparameter und kann beispielsweise mit $a_{\text{bias}} = 0,9$ gewählt werden. Für die Wahrscheinlichkeit des Übergangs in andere Zustände wird auch hier zunächst einfach eine Gleichverteilung angenommen.

$$a_{i,i} = a_{\text{bias}} \quad \forall i \in \{1, \dots, n\} \quad (5.18)$$

$$a_{i,j} = (1 - a_{\text{bias}}) \cdot \frac{1}{(n - 1)} \quad \forall i, j \in \{1, \dots, n\}, j \neq i \quad (5.19)$$

5.5 Nicht-stationäre Hidden Markov Models

Aus dem Beispiel, welches in Abb. 5.3 abgebildet ist, wird bereits ersichtlich, dass die bisher eingeführte Modellierung nicht die volle Komplexität der Situation adäquat abbilden kann. Es ist offensichtlich, dass das Verhalten des Fahrzeugs, welches in den Kreisverkehr einfahren möchte, von dem Verhalten des anderen Fahrzeugs abhängt. Verlässt das in orange gefärbte Fahrzeug nämlich den Kreisverkehr, so macht dies die Verhaltensweise, dass gelb verzögern wird, erheblich unwahrscheinlicher. Dies lässt sich in einem klassischen HMM nicht abbilden.

Stattdessen wird auf eine Variante des HMMs zurückgegriffen, die sogenannten nicht-stationären Hidden Markov Models (NSHMM). Wie der Name bereits vermuten lässt, unterscheiden diese sich von herkömmlichen HMMs darin, dass sie nicht stationär sind. Unter Stationarität versteht man die Annahme, dass die Übergangs- und Emissionswahrscheinlichkeiten A und B keinen zeitlichen Änderungen unterworfen sind. Da allerdings eine Änderung genau dieser Wahrscheinlichkeiten, beeinflusst durch das Verhalten anderer Fahrzeuge, modelliert werden soll, ergibt es Sinn, diese Annahme zu verwerfen. Daher ergeben sich nun äquivalent zu Gleichungen (5.3) und (5.5) folgende neue Definitionen für das Zustandsübergangsmodell A_t und das Beobachtungsmodell B_t im jeweiligen Zeitpunkt t :

$$A_t = \{\{a_{t,i,j}\}(i, j \in \{1, \dots, n\})\} \quad (5.20)$$

$$a_{t,i,j} := P_t(X_t = s_j | X_{t-1} = s_i) \quad \forall i, j \in \{1, \dots, n\} \quad (5.21)$$

$$B_t = \{b_{t,i}\} \quad (5.22)$$

$$b_{t,i}(o) := P_t(Y = o | X = s_i) \quad \forall i \in \{1, \dots, n\}, o \in O \quad (5.23)$$

Da die bedingten Wahrscheinlichkeiten weiterhin in jedem Zeitschritt auf den Wahrscheinlichkeiten des vorherigen Zeitschritts basieren, ändert sich beim Forward-Algorithmus durch diese Änderung nicht viel. Es gilt analog zu Gleichung (5.13):

$$P_t(s|o_{0:t}) \cdot \frac{c_{t-1}}{c_t} = P_t(o_t|s) \cdot \sum_{s_i \in S} P_{t-1}(s|s_i) \cdot P_{t-1}(s_i|o_{0:t-1}) \quad (5.24)$$

Das Beobachtungsmodell für das NSHMM bleibt dasselbe, wie bei der zuvor eingeführten stationären Variante. Somit ergibt sich die Nicht-Stationarität ausschließlich aus den Veränderungen im Zustandsraum und der Übergangswahrscheinlichkeiten bedingt durch die Interaktionen mit anderen Verkehrsteilnehmern und der daraus erfolgenden Dynamik der Verkehrssituation.

5.6 Nicht-stationärer Zustandsraum

In dem hier vorgestellten Anwendungsfall wird davon ausgegangen, dass die Wahrscheinlichkeit, dass der Fahrer eines Fahrzeugs eine bestimmte Intention hat, direkt von dem Verhalten der mit ihm in Konflikt stehenden Fahrer abhängt. Wenn des Weiteren davon ausgegangen wird, dass ein Fahrer dieselben Informationen, die den Input des hier vorgestellten Modells bilden, beobachten kann, kann daraus geschlossen werden, dass dieser ebenfalls dieselben Schlüsse über die Intention der anderen Fahrzeuge treffen kann. Deswegen wird angenommen, dass im Zeitschritt t einem Fahrer bei der Intentionsbildung die Ergebnisse der Schätzung der Intentionen der anderen Fahrzeuge durch das HMM zur Verfügung stehen. Im Falle eines menschlichen Fahrers würde diese Schätzung nicht durch ein HMM, sondern durch die menschliche Intuition und kognitive Prozesse erfolgen. Diese Informationen fließen so in die Intentionsbildung des nächsten Zeitschritts ein. Daher können die Übergangswahrscheinlichkeiten der Intentionen des Fahrers in Abhängigkeit von den Wahrscheinlichkeitsschätzungen der anderen HMMs modelliert werden. Hierdurch wird abgebildet, dass ein Fahrer keine Intention beibehalten wird, die zu einer Kollision mit einem anderen Fahrzeug führen wird. Es kommt hierdurch zu einer Wechselwirkung der HMMs für konfligierende Fahrzeuge.

In Abb. 5.5 wird gezeigt, wie sich die möglichen Intentionen aus dem hier vorgestellten Beispiel gegenseitig beeinflussen. Für das erste Fahrzeug, welches in Abb. 5.3 orange dargestellt ist, werden zwei HMMs initialisiert - eines für jeden kritischen Bereich innerhalb des Prädiktionshorizonts. Es hat zuerst die Wahl zwischen rechts und links (s_r , s_l) und falls es links fährt, die Entscheidung, ob es zuerst oder als zweites fährt ($s_{1,}$, $s_{2,}$). Das zweite Fahrzeug in Gelb hingegen hat nur die Möglichkeit, zuerst oder als Zweites zu fahren. Die hintereinandergeschalteten HMMs für Fahrzeug 1 lassen sich hier vereinfacht zu einem einzigen HMM mit 3 Intentionen zusammenfassen, wobei die




Abbildung 5.5: Visualisierung der Konflikte zwischen den unterschiedlichen Intentionen, die sich für die Fahrzeuge aus der Situation in Abb. 5.3 ergeben. Abgebildet sind jeweils die Zustandsräume, deren Wahrscheinlichkeit durch (NS)HMMs geschätzt werden. Die Intentionen s_l bzw. s_r bezeichnen jeweils die Intentionen links bzw. rechts zu fahren. Die Zahlen 1, 2 denotieren jeweils die Intentionen als erstes, bzw. als zweites zu fahren. Mit einem Blitzsymbol sind miteinander konfligierende Intentionen gekennzeichnet.

Wahrscheinlichkeiten für die „linken“ Zustände jeweils aus der Multiplikation der Wahrscheinlichkeiten für links mit den jeweiligen Wahrscheinlichkeiten für zuerst bzw. als Zweites zu fahren ergeben. Es ist ersichtlich, dass die jeweiligen Intentionen, dass beide zuerst oder dass beide als Zweites fahren, jeweils miteinander in Konflikt stehen. Um den Einfluss sich gegenseitig ausschließender Intentionen aufeinander zu modellieren, wird folgende Formel vorgeschlagen:

$$P_t(s_i|s_j) = \max(0,05, \delta_{int}), s_i, s_j \in S \quad (5.25)$$

mit:

$$\delta_{int} = P_{t-1}(s_i|s_j) + r \cdot [(1 - \sum_{s' \in S_C(s_i)} P_{t-1}(s'|o'_{0:t-1})) - P_{t-1}(s_i|s_j)] \quad (5.26)$$

Hierbei bezeichnet $S_C(s_1)$ die Menge aller Zustände anderer Fahrzeuge, die mit s_1 in Konflikt stehen, und entsprechend s' und o' die Zustände und Beobachtungen der dazugehörigen Fahrzeuge. Außerdem wird $r \in [0, 1]$ als ein Beeinflussungsfaktor eingeführt, der bestimmt, wie stark sich Fahrzeuge durch die Intentionen anderer Fahrzeuge beeinflussen lassen. Für $r = 1$ wird die Wahrscheinlichkeit direkt auf $1 - \sum_{s' \in S_C(s_1)} P_{t-1}(s'|o'_{0:t-1})$ gesetzt, für $r = 0$ werden die geschätzten Intentionen der konfiglierenden Fahrzeuge vollständig ignoriert. Es ist durch die separaten Schätzungen der Intentionen nicht ga-

rantiert, dass die Summe der geschätzten Intentionswahrscheinlichkeiten der einzelnen Fahrzeuge, auch bei konfligierenden Intentionen, einen Wert im Intervall $[0, 1]$ ergibt. Dies wäre auch bei perfekten Schätzungen der Fall, da diese konfligierenden Intentionen sich nicht gegenseitig ausschließen, sondern lediglich eine stark negative Korrelation zwischen ihnen besteht. Daher sind bei der Berechnung von Gleichung (5.26) in Grenzfällen Werte von 0 oder weniger möglich, weswegen das Ergebnis durch Gleichung (5.25) künstlich nach unten auf 0,05 begrenzt wird. Dies stellt außerdem sicher, dass eine Intention niemals vollständig durch das Verhalten anderer Verkehrsteilnehmer ausgeschlossen wird und die Möglichkeiten zur Umentscheidung mathematisch weiterhin möglich bleibt. Da außerdem nach Anwendung dieser Formel nicht mehr garantiert ist, dass sich die Summe der Wahrscheinlichkeiten aller Zustandsübergänge zu 1 addiert, werden die neu berechneten Wahrscheinlichkeiten anschließend normiert. Hierbei ist zu beachten, dass nur über die Wahrscheinlichkeiten, die zu demselben Pfad gehören, normiert wird, sodass sich nur das Verhältnis der Wahrscheinlichkeiten entlang eines Pfades verändert. Dies ist damit begründet, dass beispielsweise für Fahrzeug 1 die Wahrscheinlichkeit, ob es links oder rechts abbiegen wird, nicht durch das Verhalten von dem anderen Fahrzeug beeinflusst wird, sondern nur die Wahrscheinlichkeiten, ob es zuerst oder als Zweites fährt, gegeben, dass es überhaupt links fährt.

Neben Änderungen in den Übergangswahrscheinlichkeiten zwischen existierenden Zuständen verändert der zeitliche Verlauf des Straßenverkehrs ebenfalls die möglichen Intentionen und damit den Zustandsraum selbst. Wie bereits in Abschnitt 3.7 angedeutet, ist es möglich, dass sich die möglichen Abhängigkeiten und somit auch der Abhängigkeitsgraph durch eine Reihe unterschiedlicher Ursachen verändern. Daher ist eine durchgehende Überprüfung dessen, ob Abhängigkeiten hinzukommen oder sich verändern, notwendig, um entscheiden zu können, welche Interaktionen in welchem Zeitschritt möglich sind. Kommen neue Fahrzeuge hinzu, verlassen die Szene oder entscheiden sich für ein Szenario, welches eine andere Intention invalidiert, so ist es notwendig, dies im Zustandsraum der Intentionsschätzung zu erfassen. Hierfür werden neue Zustände dynamisch in jedem Zeitschritt erzeugt, beziehungsweise alte Zustände entfernt, falls dies notwendig ist. Um dies zu realisieren, ist eine Strategie notwendig, wie Übergangswahrscheinlichkeiten zu Zuständen, welche vorher nicht existierten, modelliert werden sollen sowie eine Strategie, wie mit der Wahrscheinlichkeitsmasse, welche auf nicht mehr existente Zustände

geschätzt wurde, umgegangen wird. Die hier angewandte Strategie lässt sich kurz in folgenden Fallunterscheidungen zusammenfassen:

Das Wegfallen von Zuständen Im ersten Fall wird eine Intention, welche in den letzten Zeitschritten plausibel war, unmöglich. Das passiert beispielsweise, falls beobachtet wird, dass Fahrzeuge sich dagegen entscheiden, einen konfligierenden Pfad einzuschlagen. In diesem Fall wird der entsprechende Zustand einfach entfernt. Weder für die Berechnung der anderen Wahrscheinlichkeiten, noch für die Übergangswahrscheinlichkeiten entstehen dadurch Inkonsistenzen, da in beiden Fällen jeweils wie in Abschnitt 5.2 und diesem Abschnitt beschrieben nach den jeweiligen Berechnungen normiert wird, sodass die Summe der Wahrscheinlichkeiten 1 ergibt. Dieser Vorgang entspricht einer Umverteilung der Wahrscheinlichkeiten bei Beibehaltung der jeweiligen Wahrscheinlichkeitsverhältnisse untereinander. Hier sind auch alternative Strategien möglich, beispielsweise eine Umverteilungsstrategie entlang des Abhängigkeitsgraphen oder zwischen Intentionen, die zu denselben Pfaden gehören. In der Praxis hat sich jedoch gezeigt, dass diese komplizierteren Strategien im Durchschnitt nicht zu besseren Ergebnissen führen.

Das Hinzukommen von Zuständen Der zweite Fall tritt insbesondere ein, wenn Fahrzeuge, welche vorher nicht bemerkt wurden oder zu weit von den entsprechenden kritischen Bereichen entfernt waren, um als relevant eingestuft zu werden, in der Nähe eines kritischen Bereichs auftauchen. Die geschätzte Wahrscheinlichkeit $P_I(s_I|o_0, \dots, o_t)$ wird für den neuen Zustand mit 0 initialisiert. Zur Initialisierung der Übergangswahrscheinlichkeiten kann wie bereits in Abschnitt 3.7 angedeutet die Bewertungsfunktion g für gegenseitige Abhängigkeiten verwendet werden. Jedes Mal, wenn ein neuer Zustand hinzukommt, wird g für den gesamten Abhängigkeitsgraphen neu ausgewertet. Die Übergangswahrscheinlichkeit zum neuen Zustand wird auf den Anteil von g für die neue Abhängigkeit an der Summe aller Abhängigkeiten des Fahrzeugs berechnet. Anschließend werden die Übergangswahrscheinlichkeiten normiert, sodass ihre Summe erneut 1 ergibt.

5.7 Markov-Annahmen im nicht-stationären Modell

NSHMMs wurden ursprünglich eingeführt, um ausschließlich zeitliche Veränderungen an den Wahrscheinlichkeiten zu modellieren. Die Emissions- und Übergangswahrscheinlichkeiten unterliegen Veränderungen, welche durch eine Funktion in Abhängigkeit von der Zeit abgebildet werden. Die zeitliche Veränderung der Übergangswahrscheinlichkeiten ist im Kontext dieser Arbeit allerdings nicht nur durch den Zeitpunkt selbst gegeben, sondern durch den zeitlichen Verlauf des Verhaltens der anderen Fahrzeuge. Betrachtet man also die gesamte Verkehrssituation statt nur das Modell eines einzelnen Fahrzeugs, so wird die Vermutung nahegelegt, dass sich hinter dieser Nicht-Stationarität eine Verletzung der ersten Markov-Annahme, die in Gleichung (5.1) formuliert wurde, verbirgt.

Die Wahrscheinlichkeit, von einem Zustand in einen anderen Zustand überzugehen, hängt immer noch primär von der aktuellen Intention des Fahrzeugs ab. Allerdings verändern sich die Übergangswahrscheinlichkeiten in Abhängigkeit von der geschätzten Intention anderer Fahrzeuge. Da diese Schätzungen wiederum in zyklischer Abhängigkeit zu der Schätzung des ursprünglich betrachteten Fahrzeugs stehen können, scheint eine indirekte Abhängigkeit zu den Zuständen mehrere Zeitschritte in der Vergangenheit zu bestehen. Diese Abhängigkeit wird außerdem nicht im aktuellen Zustand des HMMs abgebildet, sondern taucht ausschließlich in den Berechnungen der Übergangswahrscheinlichkeiten in Form von weiteren Variablen auf. Dennoch besteht hier keine Abhängigkeit zu weiter in der Vergangenheit liegenden Zuständen, sondern die Abhängigkeit besteht zu der Schätzung der Wahrscheinlichkeit der Zustände, nicht zu den tatsächlichen internen Zuständen selbst. Angenommen, das hier vorgestellte Modell eignet sich zur Intentionsschätzung, korreliert der Zustand mit der höchsten geschätzten Wahrscheinlichkeit zwar mit dem tatsächlichen internen Zustand des Fahrzeugs, dennoch besteht keine echte Abhängigkeit. Auf Ebene des einzelnen Fahrzeugs besteht somit für die Übergangswahrscheinlichkeit keine Abhängigkeit zu der Sequenz der vorherigen Zustände, wie es die erste Markov-Annahme aus Gleichung (5.1) fordert. Weiterhin hängt auch die Emissionswahrscheinlichkeit ausschließlich von der aktuellen Intention und nicht von den vorherigen Emissionen oder Zuständen ab, wie es die zweite Markov-Annahme in Gleichung (5.2) fordert.

Es kann also argumentiert werden, dass die Variablen, welche Einfluss auf die Wahrscheinlichkeiten nehmen, externe Umweltfaktoren sind, die durch die Nicht-Stationarität in einem ansonsten Markov-konformen Modell abgebildet werden. Dem entgegengesetzt ist es aber ebenso möglich zu argumentieren, dass die erste Markov-Annahme durch diese externen Variablen aufgrund der indirekten Abhängigkeit zu vergangenen Zuständen verletzt wird und es sich bei dem System hier somit nicht mehr um eine Markovkette handelt. Unabhängig davon, für welche Betrachtungsweise man sich entscheidet, hat dies allerdings keinerlei Auswirkung auf die mathematischen Vorgänge. Da die Intentionswahrscheinlichkeiten aller Fahrzeuge in jedem Zeitschritt geschätzt werden, muss in jedem Rechenschritt immer nur auf Ergebnisse des vorherigen Zeitschritts zurückgeblickt werden. Somit funktioniert der Vorgang der Intentionsschätzung ebenso wie bei regulären NSHMMs und es wurde entschieden, die Bezeichnung NSHMM im Kontext dieser Arbeit beizubehalten.

6 Experimente

Dieses Kapitel dient der Evaluation der in Kapitel 3, Kapitel 4 und Kapitel 5 vorgestellten Methoden. Hierbei wird in derselben Reihenfolge vorgegangen, wie diese im Verlaufe dieser Arbeit vorgestellt wurden. Die Modellparameter, die für die hier durchgeführten Experimente verwendet wurden, sind in Tabelle A.1 angegeben. Ermittelt wurden diese Parameter teilweise basierend auf den Ergebnissen von zwei eigens betreuten Masterarbeiten zu verwandten Themen [Spo19, Ma21] und teils aus Versuchen mit dem Versuchsfahrzeug am MRT.

Zunächst wird in Abschnitt 6.1 ein Überblick über die Umsetzung des Gesamtsystems gegeben. Abschnitt 6.2 beschreibt die Datengrundlage für Evaluationen in diesem Kapitel. In den Abschnitten 6.3, 6.4 und 6.5 werden jeweils die Ergebnisse von Kapitel 3 bis 5 präsentiert. Zuletzt werden die Ergebnisse dieser Evaluationen in Abschnitt 6.6 diskutiert.

6.1 Systemarchitektur

Der erste Schritt bei der Evaluierung der hier vorgestellten Ansätze war es, die in den jeweiligen Kapiteln vorgestellten Teilsysteme zu einem Gesamtsystem zusammenzuführen. Der generelle Ablauf, den dieses System bei der Ausführung durchläuft, ist in Abb. 6.1 abgebildet. Der erste Schritt bei der Ausführung des Systems ist die Kartenanalyse, welche in den Abschnitten 3.2 und 3.3 dargelegt wurde. Dieser Schritt ist streng genommen unabhängig vom restlichen Ablauf, da keinerlei dynamischen Informationen über die aktuelle Verkehrssituation verwendet werden, und könnte somit auch bereits im Vorhinein berechnet werden. In der hier beschriebenen Implementierung allerdings geschieht er einmal beim Start der Software und wird auf die gesamte Karte angewandt, was bei großen Karten zu einer geringen Verzögerung des Programmstarts führen kann. Denkbar wären hier auch dynamische Lösun-

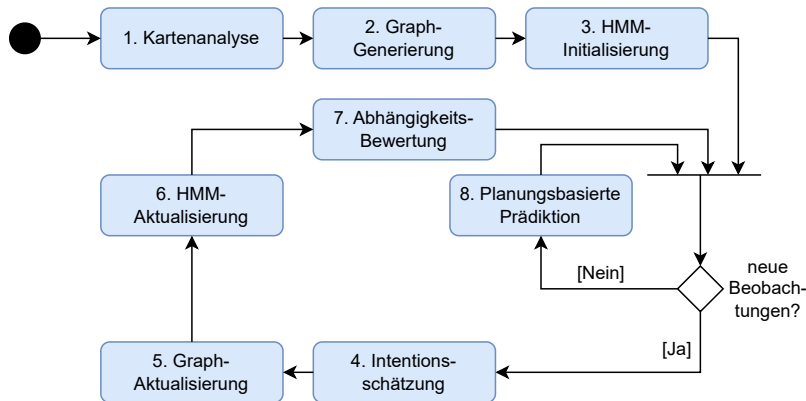


Abbildung 6.1: Eine Übersicht über den generellen Ablauf des Systems.

gen, welche im Kontext der dauerhaft laufenden Programmschleife regelmäßig weitere Kartenabschnitte nachladen und analysieren, wenn diese demnächst für das Fahrzeug relevant werden könnten. Nach diesem ersten Schritt wird eine erste Messung der dynamischen Umgebung inklusive aller anderen Verkehrsteilnehmer durchgeführt und gemeinsam mit den Ergebnissen aus dem ersten Schritt verwendet.

Basierend auf den aus dem ersten Schritt gewonnenen Interaktionspunkten und dieser ersten Messung werden im zweiten Schritt die initialen Abhängigkeiten zwischen den Fahrzeugen errechnet. Diesen Vorgang beschreiben im Wesentlichen die Abschnitte 3.5 und 3.7. Mit den kritischen Bereichen sowie den Abhängigkeiten zwischen Fahrzeugen können im dritten Schritt die HMMs initialisiert werden. Der Zustandsraum wird hierbei durch das in Abschnitt 5.4 vorgestellte Verfahren ermittelt, während die initiale Verteilung über die Zustände als Gleichverteilung modelliert wird.

Nach diesen Initialisierungsschritten beginnt eine Dauerschleife bestehend aus Schritten vier bis sieben, welche durchgehend neue Messungen auswertet und mit diesen die aktuellen Berechnungen aktualisiert. Jedes Mal, wenn eine neue Beobachtung vorliegt, wird eine Intentionsschätzung, wie sie in Kapitel 5 beschrieben wird, in Schritt vier durchgeführt, indem der nächste Zeitschritt im Forward-Algorithmus berechnet wird. Das Ergebnis dieser Intentionsschät-

zung wirkt sich im Schritt fünf auf die Abhängigkeiten zwischen den Fahrzeugen sowie auf die Wahrscheinlichkeiten, dass diese Abhängigkeiten auftreten werden, aus. Ebenso werden in diesem Schritt Änderungen am Graphen, die durch vorher nicht beobachtete Fahrzeuge verursacht werden, eingespeist. Die Kantengewichte des Graphen werden entsprechend der Art der Änderung entweder direkt an die errechneten Intentionswahrscheinlichkeiten oder an die in Abschnitt 3.7 beschriebenen Initialabschätzungen angepasst. Ebenso wie die Abhängigkeitswahrscheinlichkeiten in Schritt fünf werden im Schritt sechs die Übergangswahrscheinlichkeiten zu den einzelnen Zuständen basierend auf den geschätzten Intentionen der konfligierenden Fahrzeuge aktualisiert. Dies ist in Abschnitt 5.6 dargestellt und bildet so den Einfluss, den Fahrzeuge aufeinander haben, ab.

Nachdem die Ergebnisse der aktuellen Intentionsschätzung vollständig in den Graphen eingearbeitet wurden, findet in Schritt sieben eine Bewertung der Abhängigkeiten statt. Hier werden wie in Abschnitt 3.6 beschrieben mögliche topologische Sortierungen gesucht und anhand der Wahrscheinlichkeiten für die der Sortierung gegenläufigen Kanten bewertet. Nach diesem Schritt startet nun eine weitere Schleife, welche Schritt acht so lange ausführt, bis neue Beobachtungen gemacht werden. In diesem Schritt findet die Trajektorienplanung aus Kapitel 4 statt. Entlang der Reihenfolge der topologischen Sortierungen werden für alle beobachteten Fahrzeuge Trajektorien geplant. Diese Prädiktionen werden zum einen als Ergebnis der Trajektorienprädiktion für die jeweilige Kombination von Intentionen ausgegeben und dienen zum anderen als Grundlage für das Beobachtungsmodell der Intentionsschätzung in den folgenden Zeitschritten, wie in Abschnitt 5.3 dargelegt.

6.2 Datensätze

Durch die zugrundeliegenden Annahmen des hier vorgestellten Ansatzes ergeben sich besondere Anforderungen an die Datensätze, die zur Evaluation verwendet werden können. Da sowohl von dem Vorhandensein einer Lanelet2-Karte als auch von verdeckungsfreier Wahrnehmung der Fahrzeuge in urbanen Verkehrssituationen ausgegangen wird, wurde sich für den INTERACTION-Datensatz [ZSW⁺19] und den roundD-Datensatz [KMB⁺20] entschieden. Eine

Übersicht über weitere gängige Datensätze für das hochautomatisierte Fahren findet sich in [LYZ⁺24].

Die als Backronym entstandene Abkürzung INTERACTION steht für „An INTERNATIONAL, Adversarial and Cooperative moTION Dataset in Interactive Driving Scenarios with Semantic Maps“. Wie diese Abkürzung nahelegt, handelt es sich um eine Sammlung von Szenarien, in welchen besonders viele Interaktionen zwischen Fahrzeugen auftreten, aus mehreren Ländern. Die Szenarien wurden über einen Zeitraum von jeweils mindestens zwanzig Minuten durch mit Videokameras ausgestattete Drohnen aus der Vogelperspektive aufgenommen. Auf Basis der darauf aufgenommenen Videos wurden alle Fahrzeuge identifiziert und über den gesamten Zeitverlauf, in welchem die Fahrzeuge sich im von der Drohne sichtbaren Bereich befinden, getrackt. Diese Tracks liegen relativ zu den ebenfalls beigelegten hochgenauen Planungskarten in Form von Trajektorien vor.

Eine Besonderheit, welche durch diese Form der Datenaufnahme entsteht, ist, dass es keinerlei Verdeckungen oder anderweitige Einschränkungen der Sichtbarkeiten gibt. Stattdessen sind die genauen Positionen aller für die aktuellen Berechnungen relevanten Fahrzeuge genau bekannt. Dies ist offensichtlich nicht, wovon im Kontext des hochautomatisierten Fahrens ausgegangen werden kann, jedoch beschränkt sich der Fokus der hier durchgeführten Evaluation auf die Überprüfung der generellen Eignung der Algorithmen für die präsentierte Problemstellung. Auf eine mögliche Ausweitung der Evaluierung wird in Kapitel 7 eingegangen. Ein beträchtlicher Nachteil dieser Datensätze ist, dass Informationen fehlen, die aus einer Fahrzeugkamera gewonnen werden könnten. Beispielsweise wäre eine zusätzliche Auswertung der Fahrtrichtungsanzeiger möglich. Diese Information könnte hochgradig dazu beitragen, die Pfadintentionen der einzelnen Fahrzeuge zu erkennen. Das Vorliegen dieser Informationen wird in dem hier vorgestellten Beobachtungsmodell in Abschnitt 5.3 angenommen. Da dies hier jedoch nicht gegeben ist, wird in Abschnitt 6.5 auf Pseudo-Klassifikatoren zurückgegriffen.

Dasselbe gilt im Wesentlichen auch für den rounD-Datensatz, welcher ausschließlich Kreisverkehrssituationen in Deutschland beinhaltet. Die Datenaufnahme fand hier auf dieselbe Art und Weise wie beim INTERACTION Datensatz statt. Da in der uns vorliegenden Variante allerdings nicht die benötigten Planungskarten vorlagen, wurden diese am MRT manuell basierend auf den zugehörigen Luftbildern erstellt.




Abbildung 6.2: Die für diese Evaluation ausgewählten Szenarien aus dem INTERACTION-Datensatz. Dieser Datensatz ist auch die Bildquelle.

Für die hier vorgestellte Evaluation wurden insgesamt sieben Szenen aus diesen Datensätzen ausgewählt. Vier der Szenarien entstammen hierbei dem INTERACTION-Datensatz, drei dem round-Datensatz. Diese wurden nach den folgenden Gesichtspunkten ausgewählt: Erstens sollten diese Szenarien in einer urbanen Umgebung verortet sein. Zweitens soll der Routing-Graph der dem Datensatz beiliegenden Planungskarte tatsächlich das mögliche Fahrverhalten der Fahrzeuge in den Szenarien beschreiben. Drittens sollte das Verhalten der Fahrzeuge nicht maßgeblich durch Lichtsignalanlagen bestimmt werden, da deren Zustände nicht im Datensatz mitgeliefert werden. Die unter diesen Gesichtspunkten ausgewählten Szenarien des INTERACTION-Datensatzes sind in Abb. 6.2 illustriert und in Abb. A.1 in voller Größe angehängt. Ebenso sind die drei Szenarien aus dem round-Datensatz im Anhang A in Abb. A.3 zu finden.

Ein Beispiel für ein ungeeignetes Szenario ist in Abb. 6.3 dargestellt. Zwar lassen sich hier sinnvolle kritische Bereiche identifizieren, jedoch ist der befahrbare Bereich des Kreisverkehrs so breit, dass Fahrzeuge einander innerhalb desselben vorgesehenen Fahrstreifens überholen und passieren können. Zum




Abbildung 6.3: Ein für diesen Ansatz ungeeignetes Szenario, da die beigelegte Planungskarte nicht unter den getroffenen Annahmen das Verhalten der Fahrzeuge beschreiben kann.

einen sind deswegen nicht zwangsläufig Interaktionen zwischen Fahrzeugen an den kritischen Bereichen notwendig und zum anderen verhalten sich hintereinander fahrende Fahrzeuge nicht zwangsläufig wie in einer durch IDM beschriebenen Folgefahrt. Ähnliches gilt zwar teilweise auch für den linken Teil des in der Evaluation benutzten Szenarios, welches in Abb. A.1c abgebildet ist, dieses wurde jedoch aufgrund der geringen Ausprägung beibehalten. Ebenso ungeeignet sind Szenarien, in welchen mehrfache Spurwechsel vorkommen, da diese durch einen separaten Ansatz vorhergesagt und in das Beobachtungsmodell eingebracht werden müssten. Da dies nicht im Kontext dieser Arbeit untersucht wurde, würden diese das Ergebnis der Evaluation, die auf ortsgebundene Interaktionen fokussiert ist, verfälschen.

6.3 Evaluierung des Interaktionsmodells

In Kapitel 3 wurde die Modellierung der Abhängigkeiten zwischen einzelnen Fahrzeugen in urbanen Verkehrssituationen vorgestellt. Diese Modellierung zu evaluieren, stellt eine Herausforderung dar, da es schwierig ist, eine Ground-Truth dafür zu erhalten, welche Fahrzeuge sich in ihrem Verhalten tatsächlich beeinflusst haben. Daher wird dieses Kapitel hauptsächlich qualitativ evaluiert. Eine Visualisierung der für die einzelnen Szenarien verarbeiteten Planungskarten ist in Abb. 6.4 zu finden und größer in Abb. A.2 angehängt. Wie aus den ersten drei Szenarien ersichtlich ist, bilden die kritischen Bereiche im Wesentlichen die Punkte ab, welche man intuitiv als menschlicher

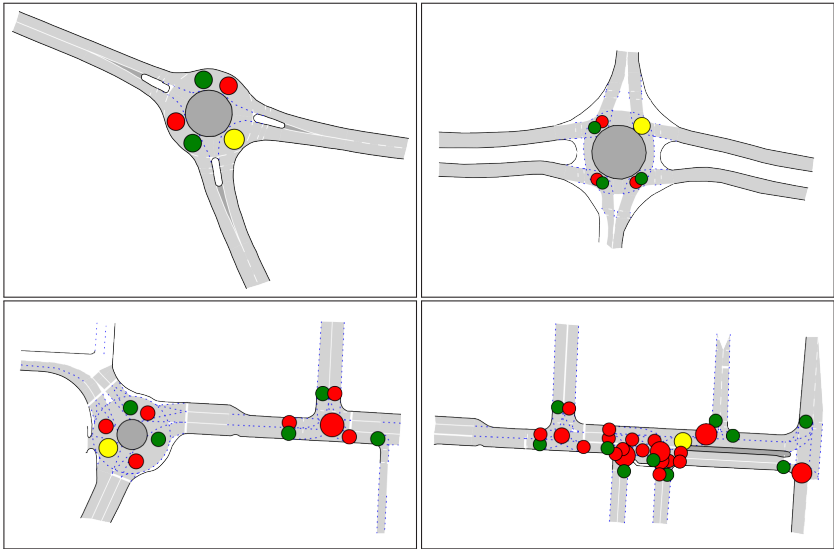


Abbildung 6.4: Das Ergebnis der Analyse der Planungskarten der in Abb. 6.2 dargestellten Szenarien.

Beobachter ebenfalls als besonders interaktionsrelevant ansehen würde. Das letzte abgebildete Szenario weist sich insbesondere dadurch aus, dass Bereiche des Szenarios mehrspurig sind, wobei Abbiegeverhalten über mehrere Spuren möglich ist. Dies führt zu einer besonderen Dichte der als kritisch erkannten Bereiche. Da dennoch immer nur eine begrenzte Menge an kritischen Bereichen direkt für einzelne Fahrzeuge erreichbar sind, wächst die Komplexität der Intentionsschätzung allerdings weniger, als die optisch wahrgenommene Dichte dies vermuten lässt. Für einzelne Fahrzeuge liegen immer nur so viele kritische Bereiche im für die Prädiktion relevanten Abschnitt des eigenen Fahrstreifens, wie Kreuzungen und Abbiegemöglichkeiten auf diesem vorhanden sind. Des Weiteren werden nur dann neue Abhängigkeiten indiziert, falls diese Interaktionsbereiche ebenfalls innerhalb des Prädiktionshorizonts von anderen Fahrzeugen erreicht werden können. In natürlichen Situationen, in welchen die lokale Dichte von Fahrzeugen stark beschränkt ist, entstehen entsprechend nur wenige Abhängigkeiten für einzelne Fahrzeuge, wodurch die Komplexität des Ansatzes nicht wesentlich im Vergleich zu anderen Situationen steigt.

6.4 Evaluierung der Trajektorienprädiktion

Der in Kapitel 4 vorgestellte Ansatz zur Trajektorienprädiktion, welcher die Grundlage für das Beobachtungsmodell der Intentionsschätzung liefert, basiert im Kern auf einer Simulation der vorhandenen Verkehrssituation gegeben einer Homotopieklasse mit dem IDM. Eine Variante dieses Ansatzes wurde auf den Versuchsfahrzeugen des MRT implementiert und lieferte für mehrere Jahre die Eingabedaten für die Planungsalgorithmen des Fahrzeugs.



Abbildung 6.5: Visualisierung einer Fahrt im echten Straßenverkehr auf dem Versuchsfahrzeug des Instituts. Die für die hellgrün abgebildeten Fahrzeuge prädizierten Trajektorien sind in Schwarz dargestellt. In Weiß sind jeweils sowohl die der Planungskarte entnommenen Fahrbahnmarkierungen sowie statische Objekte, welche von den Sensoren außerhalb der Fahrstreifen der Fahrzeuge erkannt wurden, abgebildet. Die Grenze des befahrbaren Bereiches ist in Dunkelgrün hervorgehoben.

In Abb. 6.5 ist die Visualisierung einer typischen Szene mit mehreren Fahrzeugen abgebildet, wie sie bei einer Versuchsfahrt aufgetreten ist. Zu sehen sind mehrere durch Sensorik erfasste Fahrzeuge in Grün dargestellt sowie das Fahrzeug des Instituts als schwarzes Modell. Für jedes einzelne grüne Fahrzeug wird prädiziert, dass es entsprechend den IDM den voranfahrenden Fahrzeugen auf den schwarzen Trajektorien folgen wird.

Da die Intentionsschätzung in vollem Umfang jedoch nicht Teil der in den Versuchsfahrzeugen aufgebauten Verarbeitungskette ist, wurde ein alternativer Weg implementiert, um eine kombinatorische Explosion der Verarbeitungskomplexität in Situationen mit hohem Verkehrsaufkommen zu vermeiden.

Der erste Schritt hierbei ist immer noch eine Abhängigkeitsanalyse, in welcher jedoch hauptsächlich nach Folgerelationen gesucht und kreuzende Spuren ignoriert werden. Dies bedeutet, dass Fahrbahnabschnitte, die nicht zueinander in Folgerelationen stehen, zu separaten Abhängigkeitsgraphen führen, was die Komplexität erheblich verringert. Kreuzende Spuren sowie Vorfahrtsregeln wurden auf dem Fahrzeug durch virtuelle, nicht real existierende Objekte umgesetzt. Diese blockieren den Fahrweg der Fahrzeuge, welche wegen Vorfahrtsregeln oder Lichtsignalanlagen aktuell nicht fahren dürfen.

Solche Objekte wurden erst, wenn das Umschalten der jeweiligen Lichtsignalanlage auf Grün erkannt wurde, entfernt. Um die Komplexität weiter zu verringern, wurden außerdem jeweils nur gleich bleibendes oder verzögerndes Fahrverhalten vorhergesagt und die angenommene Wunschgeschwindigkeit in den IDM-Parametern auf das Minimum der aktuell beobachteten Geschwindigkeit und der erlaubten Geschwindigkeit gesetzt. Diese Vereinfachung führt in vielen Situationen zu einer geringeren Korrektheit der Prädiktionen, sorgte aber im Kontext der umgesetzten Software für ein defensives und sicheres Fahrverhalten des Versuchsfahrzeugs.

Da dieser Ansatz über mehrere Jahre hinweg erfolgreich sowohl in regelmäßigen Testfahrten als auch in mehreren Demonstrationsfahrten für Presse und Fachpublikum verwendet wurde, sehen wir die generelle Eignung dieses Ansatzes als zwar nicht vollständig erwiesen, aber zumindest nahegelegt an.

Leider lässt sich diese empirisch gewonnene Einschätzung mit den zur Verfügung stehenden Datensätzen nur bedingt belegen. Abb. 6.6 zeigt auf demselben Kreisverkehr, der für die meisten bisherigen Illustrationen als Beispiel diente, die Abweichung der Endposition der vorhergesagten Trajektorien zu den tatsächlichen Positionen der Fahrzeuge 5 Sekunden in die Zukunft präzisiert. Quelle dieser Evaluation ist die Masterarbeit von Nicolai Spohrer, welche vom Autor dieser Dissertation betreut wurde [Spo19]. Hierbei wurden jeweils nur diejenigen Prädiktionen ausgewählt, die auf Simulationen mit der Annahme der tatsächlich umgesetzten Homotopieklasse basieren. Diese Metrik wird, sofern auf alle möglichen Prädiktionen angewandt, als Final Displacement Error (FDE) bezeichnet und wird auf gängigen Prädiktionsdatensätzen als eine von mehreren Metriken verwendet [CBL⁺20, WQA⁺21, CLS⁺19, ECC⁺21].

Während die meisten Ergebnisse nur eine Abweichung von weniger als 2 Metern aufweisen, gibt es eine kleine Anzahl von starken Abweichungen, welche




Abbildung 6.6: Quantitative Evaluation der Trajektorienprädiktion für einen Horizont von 5s auf dem Kreisverkehr in Abb. A.2a aus dem INTERACTION Datensatz. Der Mittelwert liegt bei 2,17m. Datenquelle: [Spo19]

das Ergebnis verfälschen und welche auf unvollständige Daten im Datensatz zurückzuführen sind. Hierbei handelt es sich beispielsweise um Situationen, in denen Fahrradfahrer oder Fußgänger, deren Positionen nicht im Datensatz mitgeliefert wurden, Einfluss auf das Verhalten der Fahrzeuge nehmen. Hierdurch entstehen starke Abweichungen zwischen der Prädiktion, die die Existenz dieser Verkehrsteilnehmer wegen Unvollständigkeit der Daten ignorieren muss, und den tatsächlich beobachteten Fahrzeugpositionen. Diese Ergebnisse kann man mit den in Abb. 6.7 gezeigten Ergebnissen derselben Evaluation auf einem Autobahnabschnitt mit Einfädelungstreifen vergleichen. Da das IDM ursprünglich für Längsplanung von Folgefahrten auf Autobahnen entwickelt wurde, sind in diesem Szenario erheblich bessere Ergebnisse als in urbanen Verkehrssituationen zu erwarten. Dennoch ist zu sehen, dass sich die Mittelwerte und Streuungen jeweils nur leicht unterscheiden. Hieraus lässt sich schließen, dass die Übertragung des für die Autobahn gedachten Planungsmodells auf die hier verwendeten urbanen Situationen mit kritischen Bereichen zulässig ist.

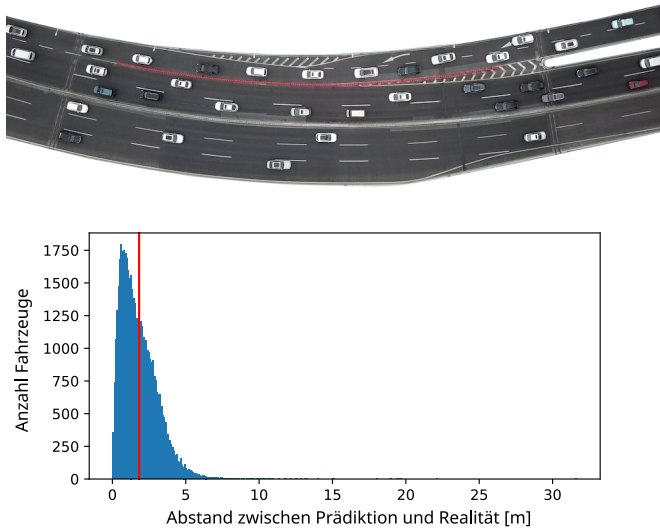


Abbildung 6.7: Quantitative Evaluation der Trajektorienprädiktion für einen Horizont von 5s auf einem Einfädelungstreifen einer chinesischen Autobahn aus dem INTERACTION Datensatz. Der Mittelwert liegt bei 1,82m. Anmerkung: Die Skalierung ist einem einzelnen Ausreißer bei etwas über 30m geschuldet. Datenquelle: [Spo19].

6.5 Evaluierung der Intentionsschätzung

In der Disziplin der Trajektorienprädiktion gibt es eine große Anzahl an denkbaren Metriken, die für die Evaluation benutzt werden können, wie beispielsweise in [QHT⁺17, WKL⁺19] gezeigt. Die hier angewandte Distanz zwischen Prädiktion und Ergebnis – der Final Displacement Error (FDE) – taucht in vielen Veröffentlichungen und Datensätzen auf und bildet so mit einigen anderen Metriken einen gewissen Standard [RPH⁺20]. Anders sieht es aber für die Evaluation von Intentionsschätzungen aus, eine Disziplin, in der sich bisher keine Metrik als Standard etablieren konnte und in der sich die Metriken in der Literatur stärker unterscheiden [GH24]. Mehrere mögliche Ansätze für die Evaluation betrachten die Intentionsschätzung als Klassifikationsproblem. Hierfür wird ein fester Prädiktionshorizont gewählt und überprüft, ob ein Schätzer eine Intention, die am Ende dieses Horizonts realisiert wird, erkennen kann. Diese Werte mögen auf dem Papier eine gewisse Vergleichbarkeit

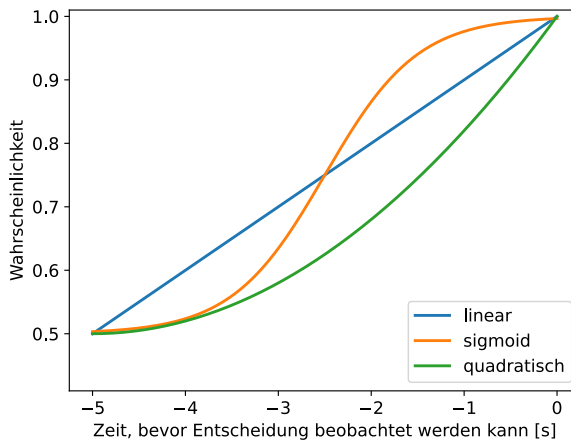


Abbildung 6.8: Verschiedene simulierte Klassifikatoren für die Pfadvorhersage. Diese simulieren Klassifikatoren, die mit vollständigeren Informationen, als sie im Datensatz vorhanden sind, Vorhersagen treffen.

zwischen verschiedenen Ansätzen, die so evaluiert wurden, herstellen, jedoch gibt es einige Aspekte, die der Disziplin der Intentionsschätzung innewohnen, die nach Meinung des Autors eine Vergleichbarkeit zwischen diesen Ansätzen stark einschränkt. Ein wesentlicher Aspekt in dieser Hinsicht ist die Definition bzw. das Verständnis vom Begriff der Intentionen. Dieser Begriff wird in vielen Veröffentlichungen unterschiedlich benutzt und bezieht sich manchmal auf einzelne Fahrmanöver, manchmal auf bilaterale Verhältnisse zwischen Fahrzeugen und manchmal auf Routen- und Spurwechselplanung. Somit ist ein Vergleich zwischen solch unterschiedlichen Verständnissen, auch wenn dieselbe Metrik verwendet wird, nicht aussagekräftig. Daher und weil dem Autor keine Veröffentlichungen bekannt sind, die sowohl eine hinreichend ähnliche Definition von Intentionen verwenden als auch eine für den Vergleich geeignete Metrik verwenden, stehen die hier vorgestellten quantitativen Ergebnisse für sich.

Um die Evaluation der Intentionsschätzung auf den in Abschnitt 6.2 beschriebenen Datensätzen durchführen zu können, fehlt für den hier beschriebenen Ansatz eine Form von Informationen, welche auf einem Versuchsfahrzeug zur

Verfügung stehen würde. Aus Kamerabeobachtungen anderer Fahrzeuge ist es auf einem Versuchsfahrzeug möglich, die Fahrtrichtungsanzeiger anderer Fahrzeuge zu erkennen und diese Information zu verwerten. Dies wurde bereits im letzten Absatz von Abschnitt 5.3 angedeutet, wo von der Existenz eines Pfadklassifikators ausgegangen wird, welcher eine gewisse Wahrscheinlichkeit für die einzelnen Pfadintentionen ausgeben kann. Um diesen Mangel an Informationen in den Datensätzen zu mitigieren, wurden im Kontext der Evaluation drei unterschiedliche Simulationen der Ergebnisse eines solchen Klassifikators verwendet. Hierfür wurde für jedes Fahrzeug jeweils im Vorhinein der Pfad, den das Fahrzeug in der Szene durchfährt, aufgezeichnet und analysiert. Anschließend wurde bei der tatsächlichen Auswertung jeweils das Ergebnis von Klassifikatoren simuliert, welche 5 Sekunden vor der beobachteten Entscheidung jeweils eine Gleichverteilung über alle möglichen Pfade ausgeben und die Pfadwahrscheinlichkeit für den korrekten Pfad bis zum Zeitpunkt der Beobachtung hin stetig erhöhen. Die drei hier verwendeten Klassifikatoren, die jeweils einen unterschiedlichen Verlauf der Wahrscheinlichkeiten im Bereich der 5 Sekunden vor Eintreffen der Entscheidung simulieren, sind für den Fall einer einfachen Entscheidung zwischen zwei Pfaden in Abb. 6.8 dargestellt. Der einfachste Klassifikator geht hierbei von einem linearen Anstieg der Wahrscheinlichkeiten aus, während der quadratische und der sigmoide Klassifikator annehmen, dass die geschätzten Wahrscheinlichkeiten eines realen Klassifikators zunächst nur langsam ansteigen sich erst zu einem späteren Zeitpunkt deutlich schneller einer hohen Sicherheit nähern.

Für jede dieser drei Annahmen über das Verhalten eines solchen Klassifikators wurde die Evaluation durchgeführt, wobei beobachtet werden konnte, dass die Wahl des Klassifikators tatsächlich nur einen geringen Einfluss auf die Gesamtperformanz des Ansatzes auf dem gesamten Datensatz hat. Dies ist unter anderem dadurch zu erklären, dass dieser Klassifikator überhaupt nur Anwendung findet, wenn der betrachtete kritische Bereich auch einen Entscheidungspunkt beinhaltet, was in dem Datensatz für weniger als die Hälfte der kritischen Bereiche der Fall ist. Allerdings ist auch bei gesonderter Betrachtung ausschließlich solcher kritischen Bereiche eine ähnliche Beobachtung zu machen. Dies legt nahe, dass der hier beschriebene Ansatz die größeren Unsicherheiten, welche der quadratische Klassifizierer liefert, kompensieren kann.




Abbildung 6.9: Die Korrektklassifikationsrate (engl.: accuracy) in Abhängigkeit davon, wie weit in der Zukunft die vorhergesagte Intention beobachtet werden kann. Links zu sehen ist der Verlauf über alle Daten. Rechts abgebildet sind die Verläufe für die einzelnen Szenarien auf dem Datensatz zum Vergleich. (Vgl. Abb. A.4)

Metriken für die Intentionsschätzung Um die Qualität der Intentionsschätzung quantitativ zu evaluieren, gibt es mehrere infrage kommende Metriken. Im Kontext dieser Arbeit wurden zwei Metriken ausgesucht, die vom Autor für diesen speziellen Ansatz für besonders aussagekräftig gehalten werden. Das Vorgehen bei beiden Metriken war hierbei im Kern dasselbe. Prädiziert wurde für jedes Fahrzeug im Datensatz jeweils die nächste Entscheidung, welche innerhalb der nächsten 30 Metern auf der aktuell befahrenen Route zu treffen ist. Es wurde sich hier für einen distanzbasierten Prädiktionshorizont entschieden, da Vorhersagen über den exakten Zeitpunkt der bevorstehenden Entscheidungen in hochinteraktiven Situationen, wie sie in den verwendeten Datensätzen vorkommen, relativ ungenau sind. Außerdem sollten auch Fahrzeuge berücksichtigt werden, welche sich nur sehr langsam (oder gar nicht) dem betrachteten kritischen Bereich nähern, zum Beispiel während sie zugunsten anderer Verkehrsteilnehmer verzögern. Um dennoch Aussagen über den zeitlichen Horizont treffen zu können, wurden jeweils nach Beobachtung des tatsächlich eingetroffenen Ereignisses die Vorhersagen zu diesem Ereignis rückwirkend datiert. Als Referenzzeitpunkt wurde hierbei jeweils derjenige Zeitpunkt betrachtet, an welchem das entsprechende Fahrzeug den relevanten kritischen Bereich vollständig verlässt. Des Weiteren wurden die Daten so gefiltert, dass nur Situationen in der Evaluation vorkommen, in welchen mindestens zwei Fahrzeuge einander beeinflussen und somit mindestens zwei Intentionen für jedes Fahrzeug möglich sind.

Wie zuvor bereits erwähnt, ist eine naheliegende Möglichkeit, eine Metrik für die Evaluation der Intentionsschätzung zu finden, die Intentionsschätzung als Klassifikationsproblem zu interpretieren. Jede Entscheidungssituation im Datensatz wird in diesem Fall als eine Zuordnung des Fahrerzustands zu möglichen Intentionen interpretiert. Somit kann man für diese Klassifikationen die Korrektorklassifikationsrate (im Englischen als „accuracy“ bezeichnet) berechnen, welche sich aus dem Verhältnis von den korrekten Klassifikationen zu der Gesamtzahl aller Klassifikationen ableitet. Diese Metrik ist am häufigsten in ähnlichen Ansätzen vertreten und ist somit am nächsten dran, sich als „Standard“ für Intentionsschätzung zu etablieren [GH24]. Eine Intentionsschätzung im Kontext dieser Metrik wird genau dann als korrekt erachtet, wenn die höchste Wahrscheinlichkeit für diejenige Intention geschätzt wird, welche für den korrekten Pfad die Abhängigkeit zu dem Fahrzeug repräsentiert, welches direkt vor dem betrachteten Fahrzeug den entsprechenden kritischen Bereich verlässt (falls vorhanden). Das Ergebnis dieser Evaluation in Abhängigkeit davon, wie weit die Beobachtung der getroffenen Entscheidung in der Zukunft liegt, ist in Abb. 6.9 unter Annahme des sigmoiden Klassifikators abgebildet, wobei sich die Ergebnisse für den linearen und quadratischen Klassifikator nur sehr gering unterscheiden. Wie man dort sehen kann, ist der hier vorgestellte Ansatz dazu in der Lage, eine 2 Sekunden in der Zukunft liegende Intention mit einer Wahrscheinlichkeit von circa 80% vorherzusagen, wobei eine Wahrscheinlichkeit von 90% bei 1,354s erreicht wird. Hier abgebildet ist lediglich ein Prädiktionshorizont von 5 Sekunden. Dies hat den Hintergrund, dass bei Prädiktionszeiträumen von über 5 Sekunden die Anzahl der Situationen stark zunimmt, in welchen die korrekte Intention noch gar nicht Teil des Zustandsraumes ist. Das passiert beispielsweise, weil das für die Intention relevante Fahrzeug noch nicht in der Szene aufgetreten ist. Somit besteht nach dem hier angewandten Verständnis von Intentionen keine Möglichkeit, die korrekte Intention zu schätzen.

Da sich die Korrektorklassifikationsrate in Abhängigkeit vom Prädiktionshorizont allerdings immer nur auf eine einzelne Klassifikation bezieht, wurde außerdem eine weitere Metrik für die quantitative Evaluation der Intentionsschätzung ausgewertet. Bei dieser wurde untersucht, ab welchem Zeitpunkt die tatsächlich realisierte Intention aus allen möglichen Intentionen durchgehend für die wahrscheinlichste gehalten wurde. Interpretiert man die Ausgabe dieses Ansatzes also so, dass die Intention mit der aktuell höchsten geschätzten Wahrscheinlichkeit als gewählte Vorhersage gilt, so gibt diese Metrik den




Abbildung 6.10: Übersicht über die Zeitpunkte, ab denen jede Entscheidung im Datensatz durchgehend korrekt vorhergesagt wird, unter Annahme eines Sigmoid-Klassifizierers. Der Durchschnitt (rot) liegt bei $-3,332\text{s}$, der Median bei $-2,9\text{s}$. Die x-Achse beginnt beim Zeitpunkt $t = 0$ der Beobachtung.

ersten Zeitpunkt an, nachdem zuletzt eine falsche Vorhersage gemacht wurde. Das Ergebnis dieser Evaluation ist in Abb. 6.10 abgebildet. Wie zu sehen ist, liefert der hier vorgestellte Ansatz im Durchschnitt ab etwa 3,3s vor Eintreffen des Ereignisses durchgehend korrekte Prädiktionen. Im Median, welcher nicht durch einzelne Ausreißer nach oben beeinflusst wird, wird ab 2,9 Sekunden vor Eintreffen des Ereignisses durchgehend die korrekte Intention geschätzt. In Abb. A.5 sind außerdem die Ergebnisse dieser Auswertung auf die einzelnen Szenarien aufgetrennt dargelegt. Abb. A.6 zeigt der Vollständigkeit halber außerdem die Ergebnisse für die beiden anderen hier vorgestellten Annahmen über das Verhalten eines Pfadklassifizierers. Diese weichen jedoch nur äußerst gering vom hier vorgestellten Ergebnis ab.

6.6 Diskussion der Ergebnisse

Wie die vorherigen Unterkapitel gezeigt haben, ist der hier vorgestellte Ansatz grundlegend dazu geeignet, in interaktiven Situationen sowohl die Intentionen als auch die geplanten Trajektorien von Fahrzeugen zu schätzen. Die Korrekt-

heit dieser Schätzungen nimmt erwartungsgemäß ab, je weiter in die Zukunft die entsprechende Größe präzisiert werden soll.




Abbildung 6.11: Ein Überholmanöver aus dem INTERACTION-Datensatz auf der Karte aus Abb. A.2b, welches exakt zum Zeitpunkt der Durchfahrt eines kritischen Bereichs durchgeführt wird. Fahrzeug 65 überholt Fahrzeug 70. Die Pfeile geben jeweils die angenommenen möglichen Abhängigkeiten an. Da dies einen Verstoß gegen die Modellannahmen darstellt, wird hier bis zum letzten Augenblick falsch vorhergesagt.

Die Evaluation zeigt jedoch auch auf, dass in seltenen Fällen bei Prädiktionen mit sehr geringem Horizont falsche Vorhersagen getroffen werden können. Hierfür sind überwiegend Verstöße gegen die Grundannahmen, auf denen der hier vorgestellte Ansatz aufbaut, verantwortlich. Ein Beispiel für einen solchen Verstoß ist in Abb. 6.11 illustriert. Hier wird gegen die Annahme aus Abschnitt 3.2 verstoßen, dass nur ein Fahrzeug auf einmal einen kritischen Bereich passieren kann. Wie zu sehen ist, befindet sich das blaue Fahrzeug mit der Nummer 70 gerade noch so im kritischen Bereich, kann diesen jedoch aufgrund der voranfahrenden Fahrzeuge nicht verlassen. Das violette Fahrzeug mit Nummer 65 überholt daher das Fahrzeug Nummer 70 und wird basierend auf seiner Position entlang der Fahrspurmittellinie bis kurz vor dem Verlassen des kritischen Bereichs als hinter Fahrzeug 70 bewertet. Da sich dies erst im letzten Zeitschritt vor Verlassen des kritischen Bereichs ändert und da dieser Zeitpunkt zugleich auch der für die Evaluation entscheidende Zeitpunkt ist, wird das Fahrzeug bis zum letzten Moment falsch präzisiert.

Ein weiterer Punkt, welcher bedacht werden sollte, ist, dass beide Metriken für die Intentionsschätzung Daten „aus der Zukunft“ verwenden und somit die Prädiktionsfähigkeit des Ansatzes evaluieren. Der Ansatz selbst hingegen schätzt genaugenommen nicht, was in der Zukunft passieren wird, sondern was die aktuelle Intention des Fahrers für die Zukunft ist. Dies vernachlässigt, dass ein menschlicher Fahrer in interaktiven Situationen seine Intention

der Situation anpassen kann. Da jedoch keinerlei Daten über die Intentionen des Fahrers vorliegen, kann nur anhand der tatsächlich umgesetzten Intention evaluiert werden. Es ist daher zu erwarten, dass die tatsächliche Qualität der Intentionsschätzung von der in der Evaluation ermittelten abweicht.

Zuletzt ist noch anzumerken, dass der verwendete Datensatz für die Evaluation nicht repräsentativ für die meisten Verkehrssituationen ist. Ein überwiegender Teil einer normalen Autofahrt findet außerhalb von hochinteraktiven Situationen, wie sie für diesen Datensatz explizit ausgesucht wurden, statt. Die in diesem Kapitel vorgestellte Evaluation konzentriert sich bewusst auf besonders herausfordernde Situationen mit einer großen Anzahl an Interaktionsteilnehmern. Es ist somit zu erwarten, dass die tatsächliche Performanz des hier vorgestellten Ansatzes in den meisten Situationen die hier vorgestellten Werte übertrifft.

7 Schlussfolgerungen und Ausblick

Dieses Kapitel bildet den Abschluss dieser Arbeit. Zunächst werden in Abschnitt 7.1 die wesentlichen Ergebnisse der Arbeit zusammengefasst. Anschließend werden mögliche Ansätze zur Verbesserung der hier vorgestellten Ergebnisse und weiterer Forschung in Abschnitt 7.2 diskutiert.

7.1 Zusammenfassung

In dieser Arbeit wurde ein Ansatz zur Verhaltensvorhersage von Fahrzeugen in interaktiven urbanen Situationen vorgestellt. Dieser Ansatz umfasst außerdem eine Methode zur Schätzung der Intentionen ebenjener Fahrzeuge sowie ein Verfahren zur Modellierung der Abhängigkeiten zwischen den jeweiligen Verhaltensmustern. Durch das Zusammenspiel dieser unterschiedlichen Modellierungen ist es möglich, sowohl Aussagen über die aktuellen Intentionen von Fahrzeugfahrern zu machen als auch probabilistische Vorhersagen sowohl über die zukünftigen Positionen der Fahrzeuge als auch über die voraussichtlich umgesetzten Homotopieklassen zu treffen.

Logisch setzt sich der hier vorgestellte Ansatz im Wesentlichen aus drei Teilen zusammen. Den ersten Teil bildet in Kapitel 3 die Abhängigkeitsmodellierung zwischen Fahrzeugen. Hier werden die wesentlichen Informationen über Topologie und Verkehrsregeln aus einer hochgenauen Planungskarte der aktuellen Verkehrssituation extrahiert und gemeinsam mit einem Abhängigkeitsgraphen und hierarchischen Strukturierungen desselben ausgegeben.

Der nächste Teil in Kapitel 4 beschäftigt sich mit der planungsbasierten Trajektorienprädiktion anderer Fahrzeuge. Diese bedient sich des Graphen aus dem vorherigen Teil und simuliert den weiteren zeitlichen Verlauf basierend auf den angenommenen (möglichen) Abhängigkeiten zwischen den Fahrzeugen. Als Planungsstrategie wurde hier eine Variante des IDMs gewählt, da diese

für die hier betrachteten Zwecke einen guten Kompromiss aus der Qualität der Ergebnisse und dem Berechnungsaufwand darstellt.

Das Herzstück des hier präsentierten Ansatzes bildet die in Kapitel 5 vorgestellte Intentionsschätzung auf Basis von nicht-stationären Hidden Markov Modellen, welche sich der Ergebnisse der vorherigen beiden Teile bedient, um die Intentionsschätzung umzusetzen. Die Intentionsschätzung selbst benutzt den Forward-Algorithmus für HMMs, wobei die Simulationen aus dem zweiten Teil einen Großteil des Beobachtungsmodells und die Ergebnisse aus dem ersten Teil den Zustandsraum bilden. Die Ergebnisse dieser Schätzungen werden anschließend benutzt, um anhand des Abhängigkeitsgraphen die Übergangswahrscheinlichkeiten der HMMs anderer beobachteter Verkehrsteilnehmer zu manipulieren. Somit wird die Stationarität der HMMs verletzt, weshalb es sich hier schlussendlich um nicht-stationäre HMMs handelt.

Die Evaluation des Ansatzes in Kapitel 6 hat gezeigt, dass die jeweiligen Ergebnisse der einzelnen Teile sich weitgehend mit den Erwartungen an den Ansatz decken. Der erste Teil wurden hierbei hauptsächlich qualitativ untersucht. Die Abhängigkeitsanalyse identifiziert augenscheinlich dieselben Bereiche, die ein Mensch für besonders relevant im Kontext von Fahrzeuginteraktionen halten würde. Die Trajektorienprädiktion wurde indirekt empirisch evaluiert, da eine Variante derselben über Jahre erfolgreich für automatisierte Fahrten am MRT verwendet wurde. Außerdem wurde eine für Trajektorienprädiktion gängige Metrik, der Positionsfehler an einem Prädiktionshorizont von 5s, ausgewertet, wodurch gezeigt werden konnte, dass bei korrekter Intentionsschätzung die Trajektorienprädiktion auch in interaktiven Situationen in den meisten Fällen einen Fehler von weniger als 2m liefert. Die Evaluation der Intentionsschätzung erfolgte quantitativ. In Ermangelung von Daten über den zeitlichen Verlauf der jeweiligen Intentionen wurden hierfür zwei Metriken herangezogen, die sich auf die Vorhersagefähigkeit der Intentionsschätzung beziehen statt auf den eigentlich geschätzten zeitlichen Verlauf der Intentionen. Die Ergebnisse ließen im Kern auch hier eine generelle Eignung des Ansatzes erkennen, wobei die wahre Performanz des Ansatzes leider nicht abschließend evaluiert werden konnte.

7.2 Ausblick

Während der hier vorgestellte Ansatz gute Ergebnisse liefert, gibt es in allen drei Teildisziplinen, die in dieser Arbeit abgedeckt werden, Möglichkeiten für künftige Verbesserungen. Die Abhängigkeitsanalyse betrachtet aktuell neben ortsgebundenen Interaktionen zwischen Fahrzeugen ausschließlich Interaktionen, die durch Folgefahrten entstehen. Dies vernachlässigt die in urbanen Szenarien eher selten vorkommenden, aber dennoch relevanten Interaktionen zwischen Fahrzeugen auf benachbarten Fahrspuren, wie sie beispielsweise durch einen Spurwechsel oder Überholmanöver entstehen können. Außerdem wäre es möglich, Ansätze zu entwickeln, welche die strikte Annahme, dass Fahrzeuge nie zugleich einen kritischen Bereich passieren können, aufweichen, indem beispielsweise transitive Abhängigkeitsübertragungen zwischen einander folgenden Fahrzeugen ermöglicht werden. Zuletzt könnte auch untersucht werden, ob sich bessere Heuristiken zum schnellen Finden von möglichst guten topologischen Sortierungen des Abhängigkeitsgraphen finden lassen, wodurch leichte Verbesserungen im Beobachtungsmodell der Intentionsschätzung zu erwarten wären.

In der Trajektorienprädiktion wäre es möglich, zu untersuchen, ob andere Planungsalgorithmen zu besseren Ergebnissen führen könnten. Da es sich bei dem hier vorgestellten Planungsalgorithmus lediglich um einen Längsplaner handelt, welcher entlang eines vorgegebenen Pfades (der Fahrspurmittellinie) prädiziert, liefert die hier verwendete quantitative Evaluation durch den Positionsfehler allein bereits durch die Abweichung der tatsächlichen Fahrzeugposition von der Mittellinie einen Fehlerwert, welcher durch eine freiere 2d-Planung vermieden werden könnte. Außerdem wäre es insbesondere im Hinblick auf die Verwendung des hier vorgestellten Ansatz in einem FAS möglich, das Ego-Fahrzeug, über welches weit mehr Informationen vorliegen (sollte), anders als die anderen Fahrzeuge der Szene zu behandeln.

Um die Intentionsschätzung weiterzuentwickeln, gibt es zwei offensichtliche Möglichkeiten. Zum einen wurde in der Evaluation die Existenz eines Pfadklassifikators angenommen, jedoch lediglich dessen Ergebnis auf dem Datensatz simuliert. Dies könnte in zukünftigen Arbeiten durch Implementierung eines Ansatzes hierfür verbessert werden. Außerdem hat die quantitative Evaluation gezeigt, dass es einige Situationen gibt, in welchen die Annahmen, die dieser Arbeit zugrunde liegen, verletzt werden, wodurch falsche Schätzungen


und somit auch Vorhersagen erhalten werden. Dies könnte erkannt und gemeldet werden, indem beispielsweise eine Rückweisungsintention eingeführt wird, welche symbolisieren soll, dass das Verhalten eines Fahrzeuges nicht den simulierten und im Zustandsraum vorhandenen Intentionen entspricht.

Zuletzt ist noch zu erwähnen, dass auf einem realen Versuchsfahrzeug nicht immer alle für die Anwendung von diesem Ansatz notwendigen Daten in hinreichender Qualität vorliegen. Durch Verdeckungen, imperfekte Algorithmen oder andere Effekte ist es möglich, dass nicht alle relevanten Bereiche der Verkehrssituation oder nicht alle relevanten Fahrzeuge wahrgenommen werden. Dies spielte auch in die Evaluationsergebnisse in gewissen Maßen hinein, da in den benutzten Datensätzen keine Fußgänger, Fahrradfahrer oder außerhalb der Karte befindlichen Fahrzeuge berücksichtigt waren, diese jedoch Einfluss auf das Verhalten der enthaltenen Fahrzeuge nahmen. In weiteren Arbeiten könnte dies explizit modelliert werden, zum Beispiel, indem den jeweiligen Zustandsräumen stets auch eine Intention „bremst für unbekannten Verkehrsteilnehmer“ hinzugefügt wird.


A Anhang




(a) DEU Roundabout OF (Deutschland)



(b) USA Roundabout SR (USA)




(c) USA Roundabout EP (USA)




(d) USA Intersection EP1 (USA)


Abbildung A.1: Vier im Kontext dieser Arbeit für die Evaluation benutzte Szenarien aus dem INTERACTION Datensatz [ZSW⁺ 19]




(a) DEU Roundabout OF (Deutschland)



(b) USA Roundabout SR (USA)




(c) USA Roundabout EP (USA)




(d) USA Intersection EP1 (USA)


Abbildung A.2: Die kritischen Bereiche der Situationen, welche bereits in Abb. A.1 aus dem INTERACTION Datensatz [ZSW⁺19] abgebildet sind.



(a) Neuweiler, Aachen



(b) Kackertstraße, Aachen




(c) Tiergarten, Alsdorf


Abbildung A.3: Die kritischen Bereiche der drei Situationen, welche im roundD-Datensatz vorgestellt wurden [KMB⁺20]

| Parameter | Beschreibung | Wert | Einheit |
|-------------------------|--|------|------------------|
| d_{\max} | Maximale Distanz zwischen kritischen Bereichen, um zusammengefasst zu werden | 3 | m |
| θ_{ω} | Maximale Winkelabweichung, damit ein Fahrzeug einem Lanelet zugeordnet werden darf | 45 | ° |
| p_{\S} | Vorfaktor zur Modellierung von Nachrang | 1,2 | – |
| t_c | Maximaler Zeitabstand, der bis zum Erreichen eines kritischen Bereichs erwartet wird | 15 | s |
| \hat{a}_{long} | Maximale longitudinale Beschleunigung | 1,2 | m/s ² |
| \hat{a}_{lat} | Maximale laterale Beschleunigung | 2,7 | m/s ² |
| b_{comf} | Angenehme Bremsbeschleunigung | 0,8 | m/s ² |
| d_0 | Minimaler Abstand zum vorausfahrenden Fahrzeug | 2 | m |
| T | Minimaler zeitlicher Abstand zum vorausfahrenden Fahrzeug | 1 | s |
| β | Beschleunigungsexponent | 4 | – |
| d_{val} | Schwellwert, ab welchem eine Trajektorienprädiktion invalidiert wird | 0,5 | m |
| σ_a | Standardabweichung der Beschleunigung im vergleichenden Beobachtungsmodell | 1,6 | m/s ² |
| σ_d | Standardabweichung der Position im simulationsbasierten Beobachtungsmodell | 1,2 | m |
| σ_v | Standardabweichung der Geschwindigkeit im simulationsbasierten Beobachtungsmodell | 1,2 | m/s |
| a_{bias} | Bestimmt, wie wahrscheinlich es initial ist, nicht die Intention zu ändern. | 0,9 | – |
| r | Faktor, wie stark Fahrzeuge sich von den Intentionen anderer beeinflussen lassen | 0,75 | – |


Tabelle A.1: Modellparameter des hier vorgestellten Ansatzes und die in der Evaluation gewählten Werte.




(a) (INT) - DEU Roundabout OF




(b) (INT) - USA Roundabout SR




(c) (INT) - USA Roundabout EP




(d) (INT) - USA Intersection EP1




(e) roundD - Neuweiler, Aachen



(f) roundD - Kackertstraße, Aachen




(g) roundD - Thiergarten, Alsdorf




(h) Alle Szenarien übereinandergelegt.


Abbildung A.4: Für jedes Szenario die Korrektklassifikationsrate in Abhängigkeit vom Prädiktionshorizont. (INT) markiert Szenarien sind aus dem INTERACTION, roundD aus dem gleichnamigen Datensatz.




(a) (INT) - DEU Roundabout OF




(b) (INT) - USA Roundabout SR




(c) (INT) - USA Roundabout EP




(d) (INT) - USA Intersection EP1



(e) roundD - Neuweiler, Aachen




(f) roundD - Kackertstraße, Aachen




(g) roundD - Thiergarten, Alsdorf


Abbildung A.5: Für jedes Szenario die Zeitpunkte, ab denen jeweils durchgehend korrekt prädiert wird, unter Annahme eines sigmoiden Pfadklassifikators. Die x-Achse beginnt bei $t = 0$ beim Zeitpunkt der Beobachtung.



(a) Linearer Klassifizierer. Der Durchschnitt liegt bei $-3,337\text{s}$, der Median bei $-2,9\text{s}$.



(b) Sigmoider Klassifizierer. Der Durchschnitt liegt bei $-3,332\text{s}$, der Median bei $-2,9\text{s}$.



(c) Quadratischer Klassifizierer. Der Durchschnitt liegt bei $-3,323\text{s}$, der Median bei $-2,9\text{s}$.

Abbildung A.6: Die Zusammenfassung aller Szenarien für die unterschiedlichen Pfadklassifikationsannahmen. Der jeweilige Durchschnitt ist in rot eingezeichnet. Die x-Achse beginnt bei $t = 0$ beim Zeitpunkt der Beobachtung.

Literaturverzeichnis

- [ADSH11] Georges S Aoude, Vishnu R Desaraju, Lauren H Stephens, and Jonathan P How. Behavior classification algorithms at intersections and validation using naturalistic data. In *2011 IEEE Intelligent Vehicles Symposium (IV)*, pages 601–606, Baden-Baden, Deutschland, 2011. IEEE.
- [AHKK17] Seifemichael B Amsalu, Abdollah Homaifar, Ali Karimoddini, and Arda Kurt. Driver intention estimation via discrete hidden Markov model. In *2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pages 2712–2717, Banff, AB, Kanada, 2017. IEEE.
- [BDCK20] Kyle Brown, Katherine Driggs-Campbell, and Mykel J Kochenderfer. A taxonomy and review of algorithms for modeling and predicting human driver behavior. *arXiv preprint arXiv:2006.08832*, 2020. letzter Zugriff 23.03.2024 <https://arxiv.org/abs/2006.08832>.
- [BFA22] Nizar Bouguila, Wentao Fan, and Manar Amayri. *Hidden Markov models and applications*. Unsupervised and Semi-Supervised Learning. Springer Nature Switzerland AG, Cham, Schweiz, 1 edition, 2022.
- [BJG08] Jørgen Bang-Jensen and Gregory Z Gutin. *Digraphs: Theory, Algorithms and Applications*. Springer Science & Business Media, London, Vereinigtes Königreich, 2008.
- [BLSIG17] Mathieu Barbier, Christian Laugier, Olivier Simonin, and Javier Ibanez-Guzman. Classification of drivers manoeuvre for road intersection crossing with synthetic and real data. In *2017 IEEE Intelligent Vehicles Symposium (IV)*, pages 224–230, Los Angeles, CA, USA, 2017. IEEE.
- [BQB18] Steffen Busch, Jannik Quehl, and Claus Brenner. High definition mapping using lidar traced trajectories. 38. *Wissenschaftlich-*

- Technische Jahrestagung der DGPF und PFGK18 Tagung in München*, 27:376–388, 2018.
- [BZS14] Philipp Bender, Julius Ziegler, and Christoph Stiller. Lanelets: Efficient map representation for autonomous driving. In *2014 IEEE Intelligent Vehicles Symposium Proceedings*, pages 420–425, Dearborn, MI, USA, 2014. IEEE.
- [CBL⁺20] Holger Caesar, Varun Bankiti, Alex H. Lang, Sourabh Vora, Venice Erin Liong, Qiang Xu, Anush Krishnan, Yu Pan, Giancarlo Baldan, and Oscar Beijbom. nuScenes: A Multimodal Dataset for Autonomous Driving. In *2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 11618–11628, Seattle, WA, USA, 2020.
- [CLS⁺19] Ming-Fang Chang, John Lambert, Patsorn Sangkloy, Jagjeet Singh, Slawomir Bak, Andrew Hartnett, De Wang, Peter Carr, Simon Lucey, Deva Ramanan, and James Hays. Argoverse: 3D Tracking and Forecasting With Rich Maps. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 8748–8757, Long Beach, CA, USA, June 2019.
- [Com68] Inland Transport Committee. Convention on Road Traffic. In *United Nations Conference on Road Traffic*, Wien, Österreich, 1968.
- [ECC⁺21] Scott Ettinger, Shuyang Cheng, Benjamin Caine, Chenxi Liu, Hang Zhao, Sabeek Pradhan, Yuning Chai, Ben Sapp, Charles R Qi, Yin Zhou, et al. Large scale interactive motion forecasting for autonomous driving: The waymo open motion dataset. In *Proceedings of the IEEE/CVF International Conference on Computer Vision*, pages 9710–9719, Virtuell durchgeführte Konferenz, 2021.
- [EDK15] Julian Eggert, Florian Damerow, and Stefan Klingelschmitt. The foresighted driver model. In *2015 IEEE Intelligent Vehicles Symposium (IV)*, pages 322–329, Seoul, Südkorea, 2015. IEEE.
- [EMGST04] Rosemary Emery-Montemerlo, Geoff Gordon, Jeff Schneider, and Sebastian Thrun. Approximate solutions for partially observable stochastic games with common payoffs. In *Proceedings of the Third International Joint Conference on Autonomous Agents*

- and Multiagent Systems, 2004. AAMAS 2004.*, pages 136–143, New York, NY, USA, 2004. IEEE.
- [Gab95] H.N. Gabow. Centroids, Representations, and Submodular Flows. *Journal of Algorithms*, 18(3):586–628, 1995.
- [GH24] Luiz G. Galvão and M. Nazmul Huda. Pedestrian and vehicle behaviour prediction in autonomous vehicle system — A review. *Expert Systems with Applications*, 238:121983, 2024.
- [GJ19] Longxiang Guo and Yunyi Jia. Modeling, learning and prediction of longitudinal behaviors of human-driven vehicles by incorporating internal human decisionmaking process using inverse model predictive control. In *2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 5278–5283, Macau, China, 2019.
- [HB19] Karel Horák and Branislav Bošanský. Solving partially observable stochastic games with public observations. In *Proceedings of the AAAI conference on artificial intelligence*, volume 33, pages 2029–2036, Honolulu, Hawaii, USA, 2019.
- [HDY⁺22] Yanjun Huang, Jiatong Du, Ziru Yang, Zewei Zhou, Lin Zhang, and Hong Chen. A survey on trajectory-prediction methods for autonomous driving. *IEEE Transactions on Intelligent Vehicles*, 7(3):652–674, 2022.
- [IQP⁺19] Ruben Izquierdo, A Quintanar, Ignacio Parra, D Fernández-Llorca, and MA Sotelo. Experimental validation of lane-change intention prediction methodologies based on CNN and LSTM. In *2019 IEEE Intelligent Transportation Systems Conference (ITSC)*, pages 3657–3662, Auckland, Neuseeland, 2019. IEEE.
- [KMB⁺20] Robert Krajewski, Tobias Moers, Julian Bock, Lennart Vater, and Lutz Eckstein. The rounD dataset: A drone dataset of road user trajectories at roundabouts in Germany. In *23rd International Conference on Intelligent Transportation Systems (ITSC)*, pages 1–6, Rhodos, Griechenland, 2020.
- [Kur30] Casimir Kuratowski. Sur le probleme des courbes gauches en topologie. *Fundamenta mathematicae*, 15(1):271–283, 1930.
- [KWE16] Stefan Klingelschmitt, Volker Willert, and Julian Eggert. Probabilistic, discriminative maneuver estimation in generic traffic scenes using pairwise probability coupling. In *2016 IEEE*

- 19th international conference on intelligent transportation systems (ITSC)*, pages 1269–1276, Rio de Janeiro, Brasilien, 2016. IEEE.
- [KZ86] Kamal Kant and Steven W. Zucker. Toward efficient trajectory planning: The path-velocity decomposition. *The international Journal of Robotics Research*, 5(3):72–89, 1986.
- [LKB⁺13] Martin Liebner, Felix Klanner, Michael Baumann, Christian Ruhhammer, and Christoph Stiller. Velocity-based driver intent inference at urban intersections in the presence of preceding vehicles. *IEEE Intelligent Transportation Systems Magazine*, 5(2):10–21, 2013.
- [LLIG11] Stéphanie Lefèvre, Christian Laugier, and Javier Ibañez-Guzmán. Exploiting map information for driver intention estimation at road intersections. In *2011 IEEE Intelligent Vehicles Symposium (IV)*, pages 583–588, Baden-Baden, Deutschland, 2011. IEEE.
- [LVL14] Stéphanie Lefèvre, Dizan Vasquez, and Christian Laugier. A survey on motion prediction and risk assessment for intelligent vehicles. *ROBOMECH journal*, 1(1):1–14, 2014.
- [LWF⁺79] Benjamin Libet, El Wood W Wright, Bertram Feinstein, Dennis K Pearl, et al. Subjective referral of the timing for a conscious sensory experience. *Brain*, 102(1):193–224, 1979.
- [LY78] C. L. Lucchesi and D. H. Younger. A Minimax Theorem for Directed Graphs. *Journal of the London Mathematical Society*, s2-17(3):369–374, 1978.
- [LYZ⁺24] Mingyu Liu, Ekim Yurtsever, Xingcheng Zhou, Jonathan Fossaert, Yuning Cui, Bare Luka Zagar, and Alois C Knoll. A survey on autonomous driving datasets: Data statistic, annotation, and outlook. *arXiv preprint arXiv:2401.01454*, 2024. letzter Zugriff 23.03.2024 <https://arxiv.org/abs/2401.01454>.
- [Ma21] Ke Ma. Inter-Vehicle-Dependency Modeling for Intention Estimation in Urban Traffic. Masterarbeit, Institut für Mess- und Regelungstechnik (MRT), Karlsruher Institut für Technologie (KIT), Karlsruhe, Deutschland, 2021.
- [MAJD⁺20] Sajjad Mozaffari, Omar Y Al-Jarrah, Mehrdad Dianati, Paul Jennings, and Alexandros Mouzakitis. Deep learning-based vehicle

- behavior prediction for autonomous driving applications: A review. *IEEE Transactions on Intelligent Transportation Systems*, 23(1):33–47, 2020.
- [PPJ⁺18] Fabian Poggenhans, Jan-Hendrik Pauls, Johannes Janosovits, Stefan Orf, Maximilian Naumann, Florian Kuhnt, and Matthias Mayr. Lanelet2: A High-Definition Map Framework for the Future of Automated Driving. In *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*, pages 1672–1679, Maui, HI, USA, November 2018.
- [PWK17] Derek J Phillips, Tim A Wheeler, and Mykel J Kochenderfer. Generalizable intention prediction of human drivers at intersections. In *2017 IEEE Intelligent Vehicles Symposium (IV)*, pages 1665–1670, Los Angeles, CA, USA, 2017. IEEE.
- [QHT⁺17] Jannik Quehl, Haohao Hu, Ömer Şahin Taş, Eike Rehder, and Martin Lauer. How good is my prediction? Finding a similarity measure for trajectory prediction evaluation. In *2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*, pages 1–6, Yokohama, Japan, 2017.
- [QHWL18] Jannik Quehl, Haohao Hu, Sascha Wirges, and Martin Lauer. An Approach to Vehicle Trajectory Prediction Using Automatically Generated Traffic Maps. In *2018 IEEE Intelligent Vehicles Symposium (IV)*, pages 544–549, Changshu, China, 2018.
- [QYW⁺19] Jannik Quehl, Shengchao Yan, Sascha Wirges, Jan-Hendrik Pauls, and Martin Lauer. Estimating Object Shape and Movement Using Local Occupancy Grid Maps. *IFAC-PapersOnLine*, 52(8):87–92, 2019. 10th IFAC Symposium on Intelligent Autonomous Vehicles IAV 2019.
- [RPH⁺20] Andrey Rudenko, Luigi Palmieri, Michael Herman, Kris M Kitani, Darius M Gavrila, and Kai O Arras. Human motion trajectory prediction: A survey. *The International Journal of Robotics Research*, 39(8):895–935, 2020.
- [SHL⁺17] Jens Schulz, Kira Hirsenkorn, Julian Löchner, Moritz Werling, and Darius Burschka. Estimation of collective maneuvers through cooperative multi-agent planning. In *2017 IEEE Intelligent Vehicles Symposium (IV)*, pages 624–631, Redondo Beach, CA, USA, 2017. IEEE.

- [SHLB18] Jens Schulz, Constantin Hubmann, Julian Löchner, and Darius Burschka. Interaction-Aware Probabilistic Behavior Prediction in Urban Environments. In *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 3999–4006, Madrid, Spanien, 2018.
- [Son21] Ruitao Song. Driver intention prediction using model-added Bayesian network. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, 235(5):1236–1244, 2021.
- [Spo19] Nicolai Spohrer. An Approach to Predicting Vehicle Behavior in Urban Environments Using Annotated Maps. Masterarbeit, Institut für Mess- und Regelungstechnik (MRT), Karlsruher Institut für Technologie (KIT), Karlsruhe, Deutschland, 2019.
- [ST13] Sayanan Sivaraman and Mohan Manubhai Trivedi. Looking at vehicles on the road: A survey of vision-based vehicle detection, tracking, and behavior analysis. *IEEE transactions on intelligent transportation systems*, 14(4):1773–1795, 2013.
- [StV23a] Deutsche Straßenverkehrs-Ordnung vom 6. März 2013 (BGBI. I S. 367), die zuletzt durch Artikel 2 der Verordnung vom 28. August 2023 (BGBI. 2023 I Nr. 236) geändert worden ist, 2023.
- [StV23b] Österreichisches Bundesgesetz vom 6. Juli 1960, mit dem Vorschriften über die Straßenpolizei erlassen werden (Straßenverkehrsordnung 1960 – StVO. 1960), die zuletzt durch BGBI. I Nr. 129/2023 geändert worden ist, 2023.
- [Taş22] Ömer Şahin Taş. *Motion Planning for Autonomous Vehicles in Partially Observable Environments*. Dissertation, Karlsruher Institut für Technologie (KIT), Karlsruhe, Deutschland, 2022.
- [tBP96] C. ten Brink and D. Popović. A collision-space approach to trajectory planning of coordinated robots. *IFAC Proceedings Volumes*, 29(1):205–210, 1996.
- [THH00] Martin Treiber, Ansgar Hennecke, and Dirk Helbing. Congested traffic states in empirical observations and microscopic simulations. *Phys. Rev. E*, 62:1805–1824, Aug 2000.
- [VHS+22] Balakrishnan Varadarajan, Ahmed Hefny, Avikalp Srivastava, Khaled S Refaat, Nigamaa Nayakanti, Andre Cornman, Kan

- Chen, Bertrand Douillard, Chi Pang Lam, Dragomir Anguelov, et al. Multipath++: Efficient information fusion and trajectory aggregation for behavior prediction. In *2022 International Conference on Robotics and Automation (ICRA)*, pages 7814–7821, Philadelphia (PA), USA, 2022. IEEE.
- [Wir23] Florian Wirth. *Conditional Behavior Prediction of Interacting Agents on Map Graphs with Neural Networks*. Dissertation, Karlsruher Institut für Technologie (KIT), Karlsruhe, Deutschland, 2023.
- [WKL⁺19] Florian Wirth, Stephan Krane, Melanie Loos, Eike Rehder, and Carlos Fernandez. What Does a Good Prediction Look Like? In *IEEE Intelligent Transportation Systems Conference (ITSC)*, pages 1594–1599, Auckland, Neuseeland, 2019.
- [WQA⁺21] Benjamin Wilson, William Qi, Tanmay Agarwal, John Lambert, Jagjeet Singh, Siddhesh Khandelwal, Bowen Pan, Ratnesh Kumar, Andrew Hartnett, Jhony Kaesemodel Pontes, Deva Ramanan, Peter Carr, and James Hays. Argoverse 2: Next Generation Datasets for Self-Driving Perception and Forecasting. In *Proceedings of the Neural Information Processing Systems Track on Datasets and Benchmarks*, Virtuell durchgeführte Konferenz, 2021. Curran.
- [XWC⁺18] Long Xin, Pin Wang, Ching-Yao Chan, Jianyu Chen, Shengbo Eben Li, and Bo Cheng. Intention-aware long horizon trajectory prediction of surrounding vehicles using dual LSTM networks. In *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*, pages 1441–1446, Maui, HI, USA, 2018. IEEE.
- [YDW23] Renteng Yuan, Shengxuan Ding, and Chenzhu Wang. Comparative Analysis of Machine-Learning Models for Recognizing Lane-Change Intention Using Vehicle Trajectory Data. *Infrastructures*, 8(11), 2023.
- [You63] D Younger. Minimum feedback arc sets for a directed graph. *IEEE Transactions on Circuit Theory*, 10(2):238–245, 1963.
- [ZSF⁺21] Ting Zhang, Wenjie Song, Mengyin Fu, Yi Yang, and Meiling Wang. Vehicle Motion Prediction at Intersections Based on the

Turning Intention and Prior Trajectories Model. *IEEE/CAA Journal of Automatica Sinica*, 8(10):1657–1666, 2021.

- [ZSW⁺19] Wei Zhan, Liting Sun, Di Wang, Haojie Shi, Aubrey Clausse, Maximilian Naumann, Julius Kümmerle, Hendrik Königshof, Christoph Stiller, Arnaud de La Fortelle, and Masayoshi Tomizuka. INTERACTION Dataset: An INTERnational, Adversarial and Cooperative moTION Dataset in Interactive Driving Scenarios with Semantic Maps. *arXiv:1910.03088 [cs, eess]*, 2019. letzter Zugriff 23.03.2024 <https://arxiv.org/abs/1910.03088>.

Eigene Veröffentlichungen

- [1] Steffen Busch, Jannik Quehl, and Claus Brenner. High definition mapping using lidar traced trajectories. *38. Wissenschaftlich-Technische Jahrestagung der DGPF und PFGK18 Tagung in München*, 27:376–388, 2018.
- [2] Marvin Klemp, Kevin Rösch, Royden Wagner, Jannik Quehl, and Martin Lauer. LDFA: Latent Diffusion Face Anonymization for Self-driving Applications. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, pages 3199–3205, Vancouver, Kanada, 2023.
- [3] Jannik Quehl, Haohao Hu, Ömer Şahin Taş, Eike Rehder, and Martin Lauer. How good is my prediction? Finding a similarity measure for trajectory prediction evaluation. In *2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*, pages 1–6, Yokohama, Japan, 2017.
- [4] Jannik Quehl, Haohao Hu, Sascha Wirges, and Martin Lauer. An Approach to Vehicle Trajectory Prediction Using Automatically Generated Traffic Maps. In *2018 IEEE Intelligent Vehicles Symposium (IV)*, pages 544–549, Changshu, China, 2018.
- [5] Jannik Quehl, Shengchao Yan, Sascha Wirges, Jan-Hendrik Pauls, and Martin Lauer. Estimating Object Shape and Movement Using Local Occupancy Grid Maps. *IFAC-PapersOnLine*, 52(8):87–92, 2019. 10th IFAC Symposium on Intelligent Autonomous Vehicles IAV 2019.
- [6] Eike Rehder, Jannik Quehl, and Christoph Stiller. Driving like a human: Imitation learning for path planning using convolutional neural networks. In *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS) Workshops*, pages 1–5, Vancouver, Kanada, 9 2017.
- [7] Florian Wirth, Jannik Quehl, Jeffrey Ota, and Christoph Stiller. PointAtMe: Efficient 3D Point Cloud Labeling in Virtual Reality. In *2019 IEEE Intelligent Vehicles Symposium (IV)*, pages 1693–1698, Paris, Frankreich, 2019.

Betreute Abschlussarbeiten

- [8] Haohao Hu. Verhaltensprädiktion von Verkehrsteilnehmern basierend auf Trajektorienclustering. Masterarbeit, Institut für Mess- und Regelungstechnik (MRT), Karlsruher Institut für Technologie (KIT), Karlsruhe, Deutschland, 2017.
- [9] Ke Ma. Inter-Vehicle-Dependency Modeling for Intention Estimation in Urban Traffic. Masterarbeit, Institut für Mess- und Regelungstechnik (MRT), Karlsruher Institut für Technologie (KIT), Karlsruhe, Deutschland, 2021.
- [10] Dongwei Pan. Image-based Environment Classification for Small Electro Vehicles. Masterarbeit, Institut für Mess- und Regelungstechnik (MRT), Karlsruher Institut für Technologie (KIT), Karlsruhe, Deutschland, 2020.
- [11] Moritz Schnetz. Effiziente visuelle Odometrie mit einer Farb- und Time-of-Flight Kamera für ARM-Prozessoren. Masterarbeit, Institut für Mess- und Regelungstechnik (MRT), Karlsruher Institut für Technologie (KIT), Karlsruhe, Deutschland, 2019.
- [12] Lin Shen. Automatische Generierung von fahrspurgenauen Karten aus Trajektorienbeobachtungen. Masterarbeit, Institut für Mess- und Regelungstechnik (MRT), Karlsruher Institut für Technologie (KIT), Karlsruhe, Deutschland, 2019.
- [13] Nicolai Spohrer. An Approach to Predicting Vehicle Behavior in Urban Environments Using Annotated Maps. Masterarbeit, Institut für Mess- und Regelungstechnik (MRT), Karlsruher Institut für Technologie (KIT), Karlsruhe, Deutschland, 2019.
- [14] Shengchao Yan. Extended Object Shape Tracking Using Local Occupancy Grid Maps. Masterarbeit, Institut für Mess- und Regelungstechnik (MRT), Karlsruher Institut für Technologie (KIT), Karlsruhe, Deutschland, 2018.