

Situationsklassifikation und Bewegungsprognose in Verkehrssituationen mit mehreren Fahrzeugen

Der Technischen Fakultät der Universität Bielefeld

vorgelegt von

Eugen Käfer

zur Erlangung des akademischen Grades

Doktor der Ingenieurwissenschaften (Dr.-Ing.)

Kornwestheim, Februar 2013

Gedruckt auf alterungsbeständigem Papier °° ISO 9706

Vorwort

In erster Linie möchte ich Prof. Christian Wöhler und Prof. Helge Ritter für ihre großartige Unterstützung während der gesamten Zeit danken. In den Zwischengesprächen an der Universität Bielefeld haben Sie mich mit zahlreichen Ideen und Anregungen bei dieser Arbeit unterstützt. Ein großer Dank geht auch an Dr. Christoph Hermes, der mit seinem Engagement und Ehrgeiz eine exzellente Zusammenarbeit ermöglichte.

Mit Höhen und Tiefen dieser recht intensiven Doktorandenzeit habe ich viel über das Leben lernen dürfen. Das Arbeiten für die Daimler AG gab mir einen hervorragenden Einblick in ein weltweit führendes Unternehmen und deren Herausforderungen.

Es hat mir stets eine Freude bereitet mit Dr. Galia Weidl zu arbeiten. Ihre konstruktive Kritik und positive Einstellung half mir in mancher Stunde. Mit einem guten Gefühl für die Herausforderungen der Situationsanalyse standen mir Dr. Gabi Breuel und Dr. Thao Dang zur Seite. Herrn Dr. Eberhard Zeeb und Anton Feldmann möchte ich für wertvolle Kritik zu der gesamten Arbeit danken.

Die Betreuung von zwei Diplomarbeiten brachte mich bei der Zusammenstellung der Arbeit weiter und war für mich sehr lehrreich. Für eine gute Zusammenarbeit möchte ich meinen Diplomanden Viktor Gomer und Christian Rothen danken.

Zuletzt möchte ich den wichtigsten Personen in meinem Leben, den Eltern, meinen Brüdern und meiner Frau Olga, für eine enorme Unterstützung in dieser Zeit danken.

Kurzfassung

Fahrerassistenzsysteme sind in der heutigen Zeit einer der erfolgversprechendsten Beiträge zu mehr Sicherheit auf unseren Straßen. Die intelligenten Helferlein unterstützen den Fahrer aktiv in kritischen Situationen oder erhöhen den Komfort während der Fahrt. Sie sind ein Meilenstein auf dem Weg zu der Vision vom unfallfreien Fahren. Mit Sensoren wie Stereokamera und Radarsystemen ausgestattete Fahrzeuge sind in der Lage die Umwelt wahrzunehmen und die Bewegungsrichtung der Verkehrsteilnehmer zu schätzen. Mit Methoden der künstlichen Intelligenz erfolgt eine Bewertung der Verkehrssituation auf Kritikalität. Je nach Kritikalität einer Situation werden unterschiedliche Warn- und Unterstützungskonzepte eingesetzt. Das Ziel ist es, den Fahrer auf eine gefährliche Situation hinzuweisen oder bei einem unvermeidbaren Unfall die Aufprallenergie durch einen Bremsengriff zu reduzieren. Gegen Auffahrunfälle im Längsverkehr gibt es bereits ein aktives Sicherheitssystem, den Bremsassistenten.

Diese Arbeit hat das Ziel die Situationsanalyse für heutige Sicherheitssysteme auf Kreuzungssituationen zu erweitern. Dazu werden Algorithmen zur frühzeitigen Erkennung von gefährlichen Kreuzungssituationen vorgeschlagen. Der Fokus des ersten Ansatzes liegt auf der Analyse aller Fahrerreaktionen zweier kreuzender Fahrzeuge. Die kollisionsfreien Kombinationen von Bewegungsoptionen spannen einen zusammengesetzten Aktionsraum zweier Fahrer auf. Aus diesem Aktionsraum wird eine Wahrscheinlichkeit für die Gefahr einer Situation abgeleitet. In einem Versuchsträger integriert zeigt unsere Gefahrenschätzung im Realverkehr eine hohe Performanz und Zuverlässigkeit. Die Vermeidung der Falschwarnungen solcher Systeme ist eine der Herausforderungen, die es hier zu minimieren gilt.

Gemessene Bewegungsmuster eines Fahrzeugs werden im zweiten Ansatz als Wissensbasis für eine Prognose eingesetzt. Bei mehreren Fahrzeugen lässt sich in den meisten Kreuzungssituationen eine Interaktion der Fahrer beobachten. Ein Modell für das Interaktionsverhalten ermöglicht eine realistischere Bewegungsprognose für mehrere Fahrzeuge.

Im letzten Ansatz werden Bewegungsmuster zweier kreuzender Fahrzeuge in Betracht gezogen. Ein Interaktionsverhalten zwischen den Fahrern liegt dort bereits in den Daten vor. Eine anschauliche und kompakte Repräsentation der interaktiven Bewegungsmuster zweier Fahrzeuge fungiert als Wissensbasis für eine Situationserkennung

und Bewegungsprognose.

Inhaltsverzeichnis

1	Einleitung	1
1.1	Gliederung der Arbeit	7
2	Situationsanalyse	9
2.1	Sensorik und Lokalisierung	10
2.2	Prognose und Gefahrenbewertung	12
3	Modellbasierter Handlungsspielraum	17
3.1	Zielstellung	17
3.2	Elementare Aktion	22
3.2.1	Handlungsgrenzen	23
3.3	Gefahrenwahrscheinlichkeit	27
3.4	Feel-Safe-Zone	29
3.5	Implementierung	29
3.6	Evaluation	35
3.6.1	Gefahrenwahrscheinlichkeiten vs. Zeitreserven	39
3.7	Aktionsspezifische Gefahrenwahrscheinlichkeit	44
3.8	Gefahrenschätzung für mehrere Fahrzeuge	45
3.9	Situationserkennung	48
3.10	Zusammenfassung	49
4	Interaktionsmodell	51
4.1	Zielstellung	51
4.2	Einzeltrajektorienprognose	53
4.2.1	Bewegungsrepräsentation und Bewegungsdatenbank	53
4.2.2	Vergleich der Bewegungsmuster	53
4.2.3	Longest Common Subsequence (LCS)	53
4.2.4	Quaternion-based Rotationally Invariant LCS (QRLCS)	54
4.2.5	Stochastische Suche in einer Bewegungsdatenbank	56
4.3	Trajektorienpaarprognose	57
4.3.1	Interaktionsmodell	58

4.4	Situationsklassifikation	59
4.4.1	Polynomklassifikator	61
4.4.2	Konfidenzabbildung	62
4.4.3	Kollisionswahrscheinlichkeit	64
4.5	Evaluation	64
4.5.1	Einfluss der gegenseitigen Sichtbarkeit	67
4.6	Zusammenfassung	68
5	Bewegungsprognose von interagierenden Fahrzeugen	69
5.1	Zielstellung	69
5.2	Bewegungsrepräsentation	71
5.2.1	Approximation mit Tschebyschow-Polynomen	72
5.3	Lloyd-Algorithmus	76
5.4	Niedrigdimensionale Repräsentation	77
5.4.1	Unsupervised Kernel Regression	77
5.4.2	Leave-One-Out-Kreuzvalidierung	79
5.4.3	Spektrale Initialisierung	80
5.4.4	Homotopie-basierende Optimierung	81
5.4.5	Definitionsbereich im latenten Raum	81
5.4.6	Zusammenfassung des UKR-Ansatzes	82
5.4.7	Gradientenabstieg und RPROP	83
5.5	Klassenspezifische Mannigfaltigkeiten	84
5.6	Nächste-Nachbarn-Klassifikation	85
5.7	Evaluation	88
5.7.1	Prognosegenauigkeit	96
5.8	Zusammenfassung	97
6	Zusammenfassung	99
	Literaturverzeichnis	103

Einleitung

Nach der Weltgesundheitsorganisation (WHO) gibt es jährlich weltweit etwa 1,2 Millionen (2003) Todesopfer an den Folgen von Verkehrsunfällen und etwa 20 – 50 Millionen Verletzte. Damit ist die Zahl der Verkehrstoten deutlich über den Opferzahlen von Krieg, Genozid oder Terrorismus. Besonders in Ländern mit schwachen bis mittlerem Einkommensniveau ist der größte Anteil der Verkehrstopfer zu beklagen. Nach WHO ist ein negativer Trend bis 2030 zu mehr Verkehrstopfern [76] zu erwarten.

In Deutschland sinkt seit 1970 die Anzahl der Verkehrstoten kontinuierlich gegen den steigenden weltweiten Trend, siehe (Abb. 1.1). Hauptursachen für Unfälle waren damals wie heute überhöhte Geschwindigkeit und das Fahren unter Einfluss von Rausch- und Betäubungsmitteln [16]. Anfang der 70er Jahre gab es über 20000 Verkehrstote. Dies war der Höchststand in Deutschland seit 1953, auf den mit zahlreichen Maßnahmen reagiert wurde. Der Staat führte 1972 eine 100 km/h Geschwindigkeitsbegrenzung auf Landstraßen ein, 1973 wurde ein maximales Blutalkoholkonzentrationswert für den Fahrer von 0,8‰ eingeführt. Im Jahre 1974 sollte die Einführung einer Richtgeschwindigkeit von 130 km/h auf Autobahnen die Raserei eindämmen. Zum Schutz der Insassen wurde im Jahre 1976 eine Gurtpflicht auf Vordersitzen eingeführt. Bis 1984 war die Anschnallpflicht straflos, danach wurden die Insassen mit einer Geldbuße verwahrt. Diese Maßnahmen führten zu einer enormen Abnahme der Verkehrstoten auf unter 10000. Damit wurde die Anzahl der Verkehrstoten pro Jahr seit 1970 halbiert. Durch die deutsche Wiedervereinigung 1989-1990 stieg aufgrund der abrupt gestiegenen Bevölkerungszahl die Anzahl der Verkehrstoten um wenige Tausend pro Jahr.

Im Jahr 2010 erhob das statistische Bundesamt 3622 Verkehrstote im Straßenverkehr. Damit bleibt das Thema Verkehrssicherheit bis heute in Deutschland eines der zentralen Themen. Zahlreiche Projekte setzen sich das Ziel die Sicherheit im Straßenverkehr zu erhöhen. Eines dieser Projekte ist "Vision Zero" [74]. Das Projekt verfolgt den Grundgedanken: Jeder Fahrer kann Fehler machen, jedoch darf ein Fehler nicht zum schweren Unfall führen. Viele Maßnahmen der Vision Zero

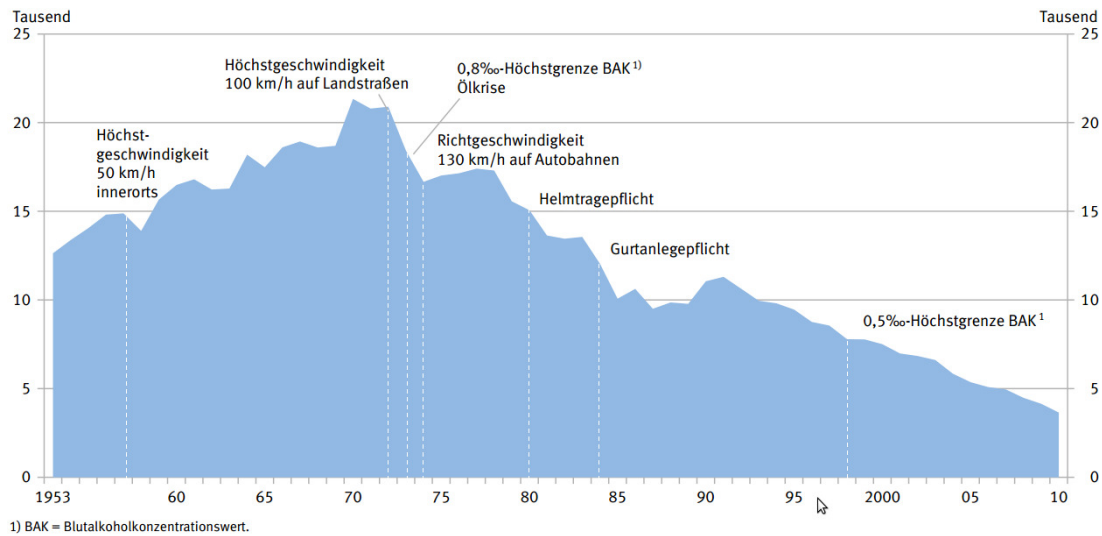


Abbildung 1.1: Anzahl der tödlich verunglückten Verkehrsteilnehmer von 1953-2010 in Deutschland mit entsprechenden Gegenmaßnahmen [16].

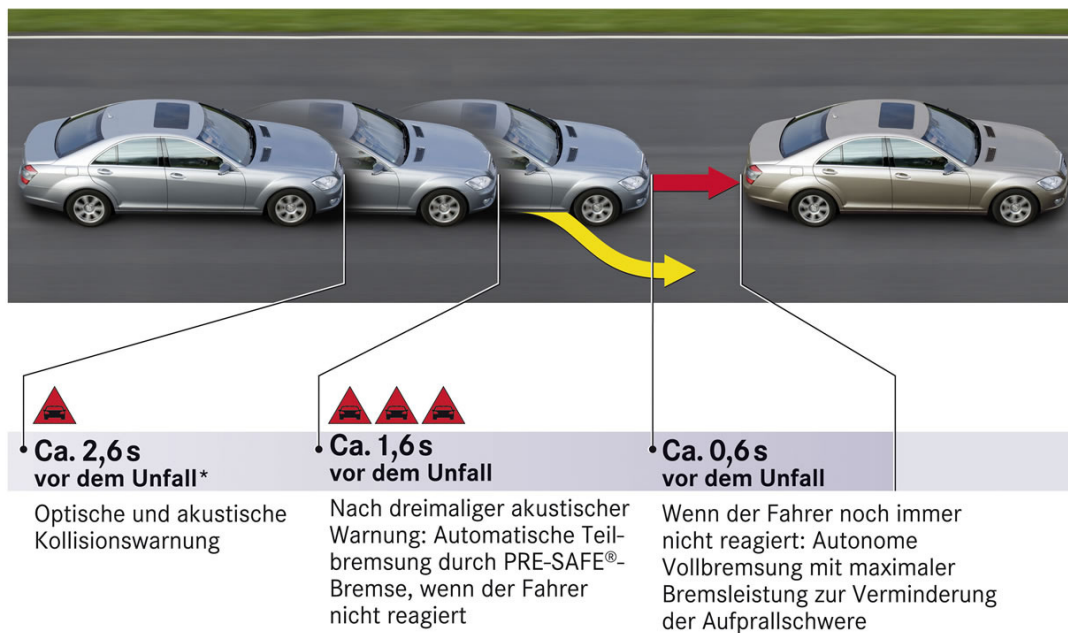
beziehen sich auf das Absichern durch die Infrastruktur. Es zeigte sich, dass übliche Verkehrskreuzungen von den Fahrern weniger beachtet werden als Kreisverkehre. Dieses führte zu der Maßnahme die Kreuzungen durch Kreisverkehre zu ersetzen. Eine Trennung der in entgegengesetzte Richtung verlaufenden Fahrstreifen erhöht den Schutz der Verkehrsteilnehmer vor Frontalunfällen. Eine sichere Infrastruktur ließ sich jedoch bis zur heutigen Zeit nicht konsequent umsetzen.

Neben derartigen Projekten entwickelt die Automobilindustrie zahlreiche innovative Sicherheitssysteme zum Schutz der Verkehrsteilnehmer. Die heutigen Sicherheitssysteme eines modernen Fahrzeugs unterteilen sich in aktive und passive Sicherheitssysteme. Systeme zur Reduktion der Folgen eines Unfalls wie z.B. der Airbag oder Sitzgurte gehören zu den passiven Sicherheitssystemen [48]. Anders verfolgen aktive Sicherheitssysteme das Ziel mögliche Unfälle zu vermeiden. Auf Basis einer Erkennung von kritischen Situationen soll der Fahrer z.B. bei der Kollisionsvermeidung unterstützt werden. Die ersten aktiven Sicherheitssysteme verfolgten das Ziel in kritischen Situationen dem Fahrer die Kontrolle über sein Fahrzeug zu sichern. Das Antiblockiersystem (ABS) [13] verhindert beim heftigen Bremsengriff das Blockieren der Räder, das zu einem Schleudern des Fahrzeugs führen könnte. Das System passt den Bremsdruck den Straßengegebenheiten, z.B. einer nassen Fahrbahn, an. Das elektronische Stabilitätsprogramm (ESP) [7] ist eine Erweiterung des ABS auf ein gezieltes Bremsen einzelner Räder, um Schleudern des Fahrzeugs im Grenzbereich zu verhindern. So kann in Kurvenfahrten sowohl ein Über- als auch ein Untersteuern des Fahrzeugs durch ein gezieltes Bremsen einzelner Räder ausgeglichen werden. Der Bremsassistent (BAS) unterstützt den Fahrer bei Notbremsungen, z.B. um Auffahrunfälle zu vermeiden, durch den Aufbau maximalen Bremspedaldrucks. Eine vom Fahrer

gewünschte Notbremsung wird durch die Dauer des Wechsels vom Gaspedal zur Bremse erkannt. Im Jahre 2006 präsentierte die Daimler AG die PRE-SAFE© Bremse [18], zur Minderung des Schadens bei Auffahrunfällen. Dieses System ist eine Erweiterung des Bremsassistenten, bei dem zusätzlich ein Radarsystem zur Erfassung von vorausfahrenden Fahrzeugen eingesetzt wird. Dieses System unterstützt den Fahrer vor einer Kollision durch akustische und visuelle Warnungen und vollführt einen autonomen Bremseneingriff, sobald der Fahrer einem vorausfahrenden Fahrzeug nicht mehr ausweichen kann. Auf Basis der relativen Geschwindigkeit der Fahrzeuge berechnet das System in wenigen Bruchteilen einer Millisekunde die Kritikalität der Situation. Dabei wird für den Fahrer des Systemfahrzeugs eine zeitliche Reserve bis zur Kollision geschätzt. Die Warnkaskade in Abb. 1.2 besteht aus einer kombinierten akustischen und visuellen Warnung 2,6 s vor einer vorhergesagten Kollision. Die Vorhersage basiert auf der relativen Geschwindigkeit beider Fahrzeuge zueinander. Reagiert der Fahrer darauf nicht, dann erfolgt 1,6 s vor der Kollision ein automatisierter Bremseneingriff mit 40 % der maximalen Bremskraft. Ein maximaler Bremseneingriff erfolgt 0,6 s vor der vorhergesagten Kollision. Präventive Insassenschutz-Systeme nützen diese Zeitreserve bis zu einer prognostizierten Kollision zur Aktivierung um z.B. den Gurt zu straffen und den Fahrer im Sitz in eine aufrichtige Position zu stellen. Der derzeitige Stand der PRE-SAFE© Bremse ist ausschließlich für Auffahrsituationen auf Autobahnen und Landstraßen ausgelegt. Nach einer Studie der Unfallforschung der Versicherer [26] reduziert ein Notbremsassistent Auffahrunfälle mit Personenschaden um 28 %.

Das vollständige Vermeiden von Unfällen bleibt eine Herausforderung. Heutige aktive Sicherheitssysteme, wie PRE-SAFE© Bremse, vermindern in den meisten Fällen die Unfallfolgen. Eine Art virtuelle Knautschzone baut die Aufprallenergie kurz vor der Kollision ab. Eine frühzeitige und zuverlässige Prognose von gefährlichen Situationen würde der vollständigen Unfallvermeidung einen Schritt näher kommen. Trotzdem soll der Mensch als Fahrer im Verkehr möglichst weit in seinem Handlungsraum uneingeschränkt bleiben. Nach der Wiener Straßenverkehrskonvention 1968, Art. 8, Absatz 5 muss der Fahrer stets die Kontrolle über das Fahrzeug behalten. Damit darf ein Fahrerassistenzsystem den Fahrer auch in kritischen Situationen nicht entmündigen.

Es lassen sich zwischen dem Konzept eines Fahrerassistenzsystems und einem Roboter Parallelen ziehen. Im Roman "Runaround" von Isaac Asimov vom Jahre 1942 wurden die wohl bekanntesten Regeln für einen Roboter aufgestellt. Nach der ersten Regel darf ein Roboter ein menschliches Wesen nicht verletzen oder auch nicht untätig gestatten, dass dem Menschen Schaden zugefügt wird. Die zweite Regel besagt, dass ein Roboter den ihm von einem Menschen gegebenen Befehlen gehorchen muss, solange er Regel eins nicht widerspricht. Die dritte Regel besagt, dass der Roboter seine Existenz schützen muss, so lange dieser Schutz nicht mit Regel eins und zwei kollidiert. Diese Regeln lassen sich auf Assistenzsysteme übertragen. Assistenzsysteme in der Rolle eines Roboters erledigen erste Überwachungsaufgaben zum Schutz der



*Vom System berechnete Zeit bis zum Aufprall bei unveränderter Relativgeschwindigkeit

Abbildung 1.2: Das PRE-SAFE®-Bremse unterstützt den Fahrer in kritischen Auffahrsituationen über eine Warnkaskade bis hin zu einer autonomen Vollbremsung [18].

Verkehrsteilnehmer.

Trotz des enormen Fortschritts bei den passiven und aktiven Sicherheitssystemen gab es nach Erhebung des Statistischen Bundesamtes in Deutschland im Jahre 2010 von Januar bis November 3622 Tote, 63493 Schwerverletzte und 296036 Leichtverletzte [70]. Um die Sicherheit im Straßenverkehr zu erhöhen, verfolgt diese Arbeit das Ziel der Erkennung von mehreren Unfallsituationen für den Einsatz in einem Bremssassistenten. Laut Statistischem Bundesamt lassen sich die Unfälle in unterschiedliche Typen bzw. Klassen aufteilen. Es werden zwei Klassen von Unfallsituationen für eine Erweiterung betrachtet:

Unfalltyp 1: Ein Fahrzeug stößt mit anderem Fahrzeug, das entgegenkommt, zusammen. Zu dieser Unfallart gehören Zusammenstöße im Begegnungsverkehr, ohne dass ein Kollisionspartner die Absicht hatte, über die Gegenspur abzubiegen.

Unfalltyp 2: Ein Fahrzeug stößt mit anderem Fahrzeug, das einbiegt oder kreuzt, zusammen. Zu dieser Unfallart gehören Zusammenstöße mit dem Querverkehr und Kollisionen mit Fahrzeugen, die aus anderen Straßen, Wegen oder Grundstücken einbiegen oder dorthin abbiegen wollen.

Die Diagramme in Abb. 1.3 veranschaulichen den Anteil der beiden Unfalltypen im Verhältnis zu den Gesamtunfällen. Die Unfälle werden nach dem Verletzungsgrad der Opfer aufgeteilt: Leichtverletzte, Schwerverletzte und Tote. Die Unfalltypen sind zusätzlich bezüglich des Ortes unterteilt, in innerorts und ausserorts.




Abbildung 1.3: Unfallstatistiken bei einem Zusammenstoß mit einem entgegenkommenden, einem kreuzenden und einem einbiegenden Fahrzeug für unterschiedliche Unfallschwere. Jede Situationsklasse wird separat innerorts und ausserorts betrachtet [70].

Ein Viertel aller Unfälle mit leichtverletzten Opfern finden innerorts bei einem Zusammenstoß mit einbiegenden und kreuzenden Fahrzeugen statt. Insgesamt bilden die Unfallzahlen mit entgegenkommenden, kreuzenden und einbiegenden Fahrzeugen sowohl innerorts als auch ausserorts ungefähr ein Drittel aller Unfälle und das bei allen drei Unfallschweren. Ausserorts hebt sich die Anzahl der Toten aufgrund höherer Geschwindigkeiten besonders hervor. Ein aktives Sicherheitssystem, wie z.B. ein Bremsassistent, für diese Unfalltypen kann einen enormen Beitrag zur Steigerung der Sicherheit im Straßenverkehr leisten.

In den Jahren 2006 -2010 wurde die Forschungsinitiative deutscher Unternehmen *aktiv* zu mehr Sicherheit mit aktiven Systemen ins Leben gerufen. Ein Kreuzungsassistent [77] wurde von der Daimler AG während der Abschlussdemonstration auf dem VTM-Testgelände in der Stadt Mendig vorgestellt. Bei einer Vorfahrtmissachtung greift das System autonom ein und verhindert eine Kollision mit einem entgegen-

kommenden Fahrzeug [1] (siehe Abb. 1.4).

Seit 2010 läuft das EU-geförderte Projekt Ko-FAS, das sich als Forschungsziel gesetzt hat die Verkehrssicherheit durch intelligente Fahrerassistenzsysteme zu steigern. Die Herausforderung einer zuverlässigen Erkennung der Situationen soll durch das Zusammenführen der Daten von mehreren Sensoren erfolgen. Dazu werden nicht nur Fahrzeuge sondern auch Kreuzungen mit Sensoren und Kommunikationseinheiten ausgestattet. Mit Hilfe einer kooperativen Perzeption soll das Fahrerassistenzsystem eine genauere und größere Umweltübersicht über eine Verkehrssituation zur Verfügung haben. Hinzu kommt, dass verdeckte Gefahren, die im Schatten der eigenen Sensoren liegen, durch andere Verkehrsteilnehmer kommuniziert werden sollen [46].




Abbildung 1.4: Auf dem linken Bild ist der Anwendungsfall des Kreuzungsassistenten, der den Fahrer im unteren Fahrzeug bei einer Vorfahrtmissachtung unterstützt. Rechtes Bild ist ein Schnappschuss von der Demonstration des Kreuzungsassistenten auf dem VTM-Testgelände in Mendig [1].

Die Basis für eine zuverlässige Schätzung der Kritikalität einer Situation ist die zuverlässige Erkennung der Umwelt, speziell der anderen Verkehrsteilnehmer. Für die Erweiterung des Anwendungsfalls eines Bremsassistenten auf beliebige Situationen im Straßenverkehr sollte die Analyse der Verkehrssituation folgende Eigenschaften aufweisen:

1. Frühzeitige Erkennung der Gefahr durch eindeutige Bewegungsprognose
2. Vermeidung von Fehlauflösungen und Falschwarnungen zur Akzeptanzsteigerung des Systems durch den Fahrer
3. Geringe Rechenkomplexität für eine schnelle Reaktion auf wechselnde Situationen

Bei der Vermeidung von Unfällen sind Bruchteile einer Sekunde viel Zeit. In dieser Zeit kann ein aktives Sicherheitssystem in kritischen Situationen den Insassen das

Leben retten. Eine schnellstmögliche Reaktion auf unerwartete Situationsänderungen erfordert Algorithmen mit kurzer Rechenzeit zur Gefahrenschätzung. Der Schlüssel für eine zuverlässige und frühzeitige Gefahrenschätzung liegt in der Prognose der Fahrzeugbewegung, die wiederum von der Fahrer-Intentionserkennung abhängt. Der Mensch ist generell ein großer Unsicherheitsfaktor, dessen Verhalten es im Verkehr zu deuten gilt. Die erste Erkenntnis ist, dass die Intention eines Fahrers von vielen Faktoren abhängt. Zum Beispiel verhält sich ein ortskundiger Fahrer in komplexen Kreuzungssituationen sicherer als einer, der zum ersten Mal über eine Kreuzung in einer fremden Stadt fährt. Der vitale Zustand des Fahrers hat einen Einfluss auf seine Fähigkeit die Situation richtig einzuschätzen. Die Folgen einer Fehleinschätzung wäre ein fehlerhaftes Handeln, das zu einer kritischen Situation führen könnte.

Ein Fahrerassistenzsystem sollte in erster Linie den Fahrer unterstützen. Welche Auswirkungen hätte ein aktives Sicherheitssystem bei einer Falschauslösung? Im Falle eines Bremsassistenten wäre ein mögliches False-Positive-Szenario: Ein Fahrzeug bremst in einer unkritischen Situation. Nicht nur für den Fahrer wäre das ein unerwarteter Eingriff, sondern auch für den Folgeverkehr, der eventuell mit der Reaktion nicht gerechnet hat. Das Risiko eines Auffahrunfalls mit Folgeverkehr steigt mit einer Falschauslösung an. Die Ursache für eine Falschauslösung kann auf Basis mangelnder Information zu der vorliegenden Situation liegen oder durch eine Überschätzung der Gefahr. Deshalb ist der Umgang mit einer begrenzten Informationsmenge über eine Situation enorm wichtig. Die Absicht des Fahrers bleibt eine Unsicherheit und wird in Form von Wahrscheinlichkeitsverteilungen berücksichtigt.

1.1 Gliederung der Arbeit

Die Situationsanalyse als Teil der Datenverarbeitung eines Assistenzsystems wird im Kapitel 2 diskutiert. Die Ansätze zur Erkennung von Kreuzungssituationen und der Gefahrenschätzung lassen sich in drei Kapitel aufteilen. Jeder dieser Ansätze unterscheidet sich durch die Zielstellungen und Techniken. Der erste Ansatz zur Gefahrenschätzung für Kreuzungssituationen zwischen zwei Fahrzeugen wird im Kapitel 3 vorgestellt. Für die Prognose der Fahrzeugbewegung werden elementare und typische Fahrerreaktionen gefiltert und repräsentieren den Aktionsraum des Fahrers. Zwischen zwei Fahrern wird mittels der Kollisionserkennung ein kollisionsfreier Handlungsspielraum berechnet und daraus eine Gefahrenwahrscheinlichkeit abgeleitet.

Eine neue Bewegungsrepräsentation im Kapitel 4 in Form von im Realverkehr beobachteten Trajektorien ermöglicht eine Reduktion des Aktionsraumes. Eine Datenbank aus Bewegungsmustern eines einzelnen Fahrzeugs stellt einen Wissensspeicher dar, auf das über die Methoden von Musterklassifikation zugegriffen wird. Ein Interaktionsmodell ergänzt die Bewegungsprognose für zwei Fahrzeuge.

Der Wissensspeicher wird im Kapitel 5 durch Bewegungsmuster zweier interagierender Fahrzeuge ersetzt. Eine Kompression der Bewegungsmuster über eine nichtlineare

Regression veranschaulicht das Modell. Dieser Ansatz ist eine Alternative zu dem Interaktionsmodell aus dem Kapitel 4.

Kapitel 2

Situationsanalyse

Die heutigen Bremsassistenten, die von Automobilherstellern verkauft werden, berücksichtigen ausschließlich die Auffahrunfälle. Eine Gefahrenschätzung im Längsverkehr ist relativ zum Kreuzungsverkehr nicht so komplex, da sich die Dynamik der Fahrzeuge auf eine Spur begrenzt. Anders ist es in Kreuzungssituationen, in denen zusätzlich Abbiegemanöver berücksichtigt werden müssen. Für eine zuverlässige Schätzung einer Gefahr in Kreuzungssituationen werden Ansätze gefordert, die mit rechenintensiveren Algorithmen einhergehen.

Die Datenverarbeitung eines aktiven Sicherheitssystems, wie z.B. eines Bremsassistenten, lässt sich durch einen sequenziellen Verarbeitungsprozess in Abb. 2.1 veranschaulichen. Die Erfassung der Umwelt einschließlich der Lage und Bewegungsrichtung der Verkehrsteilnehmer erfolgt über die Onboard-Sensoren. Dieser Teil gehört zum Prozessabschnitt Sensorik. Die Onboard-Sensoren weisen unterschiedliche Genauigkeiten bei der Erfassung der Umgebung auf, weshalb sie in den meisten Fällen miteinander fusioniert werden. Damit werden Synergie-Effekte in Form einer genaueren Lokalisierung der Verkehrsteilnehmer erzielt. Die Topologie einer Kreuzung in Form einer digitalen Karte liefert den wahrscheinlich befahrbaren Freiraum für die Prognose der Fahrzeugbewegung. Es gibt Ansätze zur Erzeugung einer Karte während der Fahrt, die als SLAM-Verfahren [73] (Simultaneous localization and mapping) bekannt sind. Die Prozessabschnitte Bewegungsprognose und Gefahrenbewertung bilden die Situationsanalyse. Der Input für die Bewegungsprognose ist eine virtuelle Umgebung, die das erkannte Abbild der realen Welt ist, bestehend z.B. aus einer Kreuzungstopologie mit dynamischen Verkehrsteilnehmern und stationären Hindernissen wie z.B. parkenden Autos. Aus der Bewegungsprognose wird die Gefahr für eine Situation geschätzt. Mehrere Ansätze für die Situationsanalyse werden in dieser Arbeit aufgezeigt. Die Unterschiede in den Ansätzen hängen unter anderem von der Informationsmenge der digitalen Welt ab. Bei einer Umsetzung eines Systems für den realen Verkehr kann derzeit nicht auf eine flächendeckende Kreuzungstopologie zugegriffen werden.

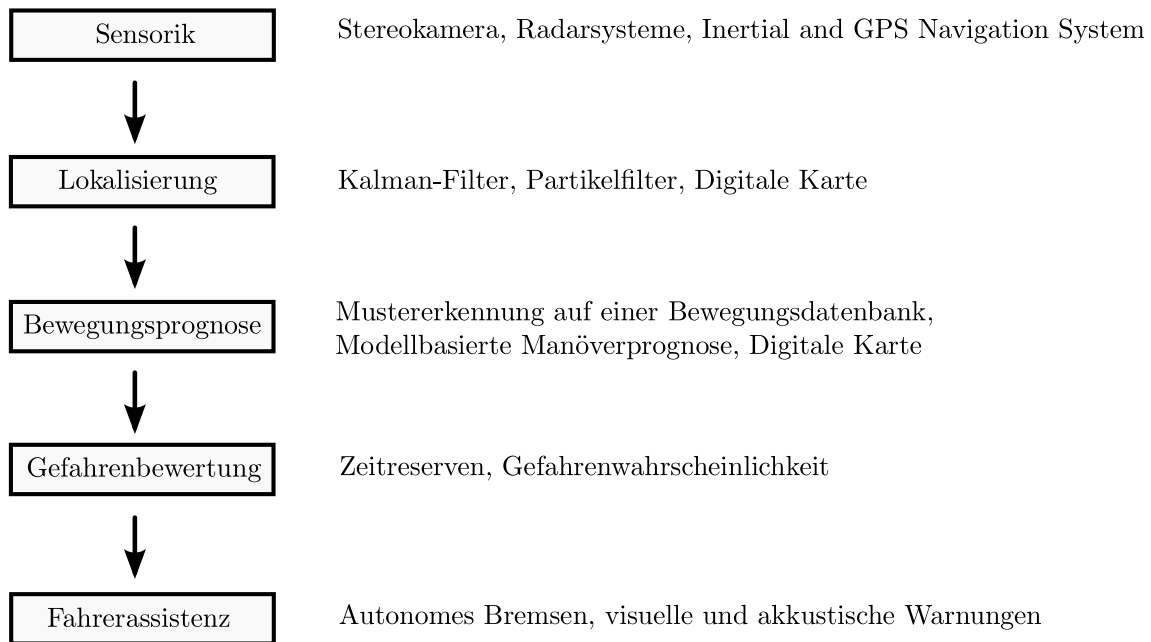


Abbildung 2.1: Übersicht über die einzelnen Schritte der Datenverarbeitung.

2.1 Sensorik und Lokalisierung

Bei den heutigen Bremsassistenten wird ausschließlich Radartechnik eingesetzt. Ein aktuelles Serienfahrzeug der Daimler AG verfügt über zwei verbaute Radartypen. Ein Fernradar mit 77 Gigahertz (siehe Abb. 2.2b) sitzt zentral in der Kühlermaske und reicht 150 m weit. Zwei zusätzliche Nahbereichssensoren mit 24 Gigahertz sitzen hinter der Stoßfängerverkleidung an den Seiten. Sie weisen eine Reichweite von 30 Metern und einen Abtastwinkel von 80 Grad in Fahrtrichtung auf. Die Stärke eines Radarsystems liegt in der Messung einer Entfernung zu einem vorausfahrenden Fahrzeug. Für den Einsatzbereich eines Bremsassistenten im Längsverkehr ist diese Informationsmenge ausreichend. Das Radar sendet elektromagnetische Wellen im Radiofrequenzbereich und die Wellen werden von Gegenständen reflektiert. Über einen Empfänger werden bestimmte Stellen der Gegenstände in Form von Punkten detektiert. Eine Entfernung zu einem Hindernis lässt sich über Radar relativ genau messen. Wegen der geringen Anzahl von reflektierten Punkten kann die Abmessung und die Orientierung des Fahrzeugs nicht genau genug geschätzt werden.

Ein mögliches Setup von Onboard-Sensoren in einem Versuchsträger erlaubt eine echtzeitfähige Erkennung der entgegenkommenden Fahrzeuge [25]. Eine Stereokamera ist einer der Onboard-Sensoren, der aus zwei leicht versetzten Monokameras aufgebaut wird (siehe Abb. 2.2a). Damit ist die Stereokamera in der Lage aus zwei versetzten Bildern nicht nur Tiefeninformation zu gewinnen, sondern auch über die Zeit eine Bewegung der Bildpartien zu schätzen. In Abb. 2.3 wird auf dem LCD-Monitor in der Mittelkonsole des Versuchsträgers ein vorausfahrendes Fahrzeug als bewegtes Objekt

(rot) im Bild detektiert. Eine Schätzung der Orientierung und der Fahrzeugabmessungen eines Fahrzeugs werden in den Arbeiten von Barrois et al. [5] diskutiert. Die Genauigkeit der Lokalisierung und die Schätzung der Bewegungsrichtung eines Fahrzeugs wird durch das Zusammenführen bzw. Fusionieren der unterschiedlichen Onboard-Sensoren erhöht [78].



(a) Stereokamera hinter der Windschutzscheibe [17].



(b) Fernradar hinter der Kühlermaske mit einer Frequenz von 77 Gigahertz und einer Reichweite von 150 m [19].

Abbildung 2.2: Onboard-Sensoren für einen Fahrzeug zur Erfassung der Umwelt.

Aufgrund des Messrauschens der Sensoren werden die Objekte über die Zeit getrackt bzw. gefiltert. Es gibt zwei weit verbreitete Methoden zum Tracken beweglicher Objekte. Ein verbreiteter Ansatz ist das Kalman-Filter [43], das in der Arbeit von



Abbildung 2.3: 6D-Vision auf Basis einer Stereokamera [17].

Barth et al. [6] auf das Tracken von Fahrzeugen angewendet wurde. Die andere Methode ist ein Particle-Filter [11], den Hermes et al. [34] auf die Schätzung der Fahrzeugbewegung angewendet hat. Der Unterschied zwischen diesen beiden Ansätzen ist, dass das Particle-Filter [20] gegenüber einem Kalman-Filter eine Schätzung von multimodalen Verteilungen erlaubt, d.h. mehrere unterschiedliche Zustandshypothesen können parallel verfolgt werden. Eine Erweiterung des Kalman-Filters auf mehrere Modelle, die miteinander interagieren und damit eine Multimodalität erlauben, wurde z.B. von Farmer et al. [24] vorgeschlagen.

2.2 Prognose und Gefahrenbewertung

In die Situationsanalyse fließen alle Informationen, wie Zustände und Abmessungen der Fahrzeuge, sowie der befahrbare Freiraum zu einem verständlichen Gesamtbild einer Situation ein. Je nach Verfügbarkeit der Informationen kann eine Situation unterschiedlich bewertet werden. Ein wichtiger Schritt in der Situationsanalyse ist eine Prognose der Bewegung der Verkehrsteilnehmer. Die Bewegung eines Fahrzeugs wird durch eine Trajektorie repräsentiert, die durch einen zeitlichen Prognosehorizont begrenzt ist. Die zukünftige Bewegung hängt unter anderem von den Absichten des Fahrers ab und kann deshalb nur geschätzt werden. Deshalb bringt eine Bewegungsprognose gewisse Unsicherheiten mit sich. Prognostizierte Trajektorien unterschiedlicher Fahrzeuge lassen sich auf Kollision prüfen und Information über die Kritikalität bzw. Gefahr der vorliegenden Situation aufzeigen.

Die Ansätze zur Gefahrenbewertung werden in zwei Kategorien aufgeteilt: deterministische und stochastische Verfahren [22]. Ähnlich lässt sich die dazugehörige Bewegungsprognose in eine dieser beiden Kategorien aufteilen. Es gibt die deterministische Bewegungsprognose, bei der nur eine Bewegungshypothese pro Verkehrsteilnehmer aufgestellt wird. Die andere Prognosekategorie ist eine probabilistische Bewegungsprognose mit einer Verteilung von Bewegungshypothesen. Hierfür wird in dieser Arbeit die Prognoseunsicherheit bzgl. des zukünftigen Fahrerverhaltens mit einer Wahrscheinlichkeitsverteilung modelliert.

In Abb. 2.4 werden die unterschiedliche Prognosetypen dargestellt. Für den Längsverkehr gibt es einen Ansatz, bei dem die Bewegungsprognose auf einen Pfad in der Mitte der Spur beschränkt wird. Es wird angenommen, dass beide Fahrzeuge ausschließlich innerhalb der Spur bleiben, siehe Abb. 2.4a. Innerhalb dieser Spur lassen sich mit longitudinaler Beschleunigung als Freiheitsgrad unterschiedliche Bewegungshypothesen aufstellen. Eine Erweiterung dieser Spurprognose auf Kreuzungssituationen ist in Abb. 2.4b dargestellt. Es wird für jedes Fahrzeug pro Kreuzungsarm ein Pfad angelegt. Der Bewegungsfreiraum eines Fahrzeugs wäre somit auf eine Dimension entlang des Pfades begrenzt. Der Nachteil bei dieser Pfadprognose entsteht bei Manövern, die sich außerhalb des vordefinierten Pfades abspielen und die dann gesondert betrachtet

werden müssen. In dieser Arbeit sollen ausschließlich Bewegungsprognosen untersucht werden, die mehrere mögliche bis hin zu beliebig vielen Bewegungsformen an Kreuzungen zulassen (siehe Abb. 2.4c). Dabei ist es unabdingbar möglichst vielfältige Bewegungsmuster bei der Prognose zu betrachten, denn es ist offensichtlich, dass kritische Situationen durch unerwartete Manöver entstehen.




Abbildung 2.4: Unterschiedliche Konzepte einer Bewegungsprognose: (a) Im Längsverkehr ein Pfad bezüglich einer Spur; (b) Für jede Bewegungsoption schienenartige Pfade auf Kreuzungen verlegt; (c) Pfade mit beliebigem Verlauf auf einer Kreuzung

Eine Reihe von beobachteten Fahrzeugpfaden wird in der Abb. 2.5 veranschaulicht. Die Abbiegepfade variieren deutlich in der Form, von früh gestarteten Abbiegemanövern bis spät gestarteten. Diese Variation stammt vermutlich aus der Interaktion der entgegenkommenden Fahrzeuge. Um diese Bewegungsmuster genauestens vorherzusagen eignet sich eine Bewegungsprognose des Typs aus Abb. 2.4c, der unterschiedliche Formen der Pfade zulässt.

Die Bewegungsprognose ist die Eingabe für die Gefahrenbewertung. Das Ziel der Gefahrenbewertung ist das Bestimmen einer Gefahrenstufe für eine Situation. Je nach Gefahrenstufe ist das Ziel eines aktiven Sicherheitssystems den Fahrer auf unterschiedliche Weise zu unterstützen. Hierfür kann das Warnkonzept von PRE-SAFE[®] Bremse, das im Kapitel 1 vorgestellt wurde, bei einer ansteigenden Gefahr durch eine Warnkaskade von akustischen/visuellen bis hin zu kinästhetischen Signalen auch für zukünftige Sicherheitssysteme uneingeschränkt eingesetzt werden.

Die Gefahrenbewertung für Situationen im Längsverkehr mit unterschiedlichen Zeitreserven und Kritikalitätsmaßen werden von Zhang et al. in [80] verglichen. Die Kinematik für die Bewegungsprognose ist meistens auf eine Spur begrenzt. Ausschermanöver der Fahrzeuge wären zwar im Realverkehr zum Ausweichen eine Option, werden jedoch dabei nicht berücksichtigt.

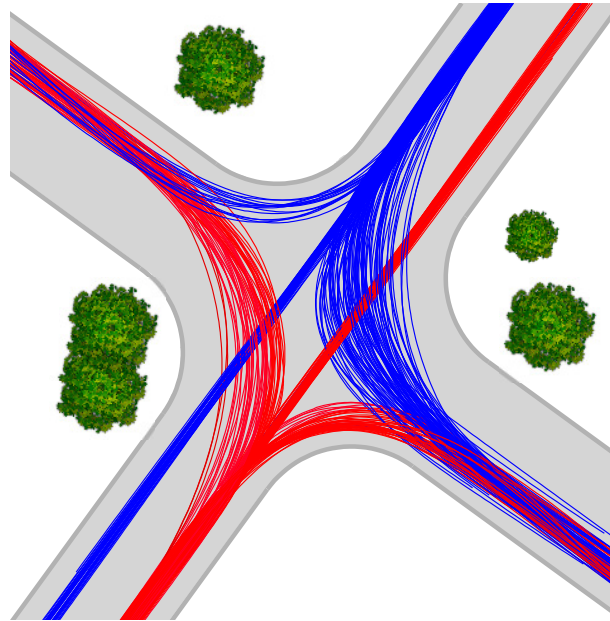


Abbildung 2.5: Aufgezeichnete Kreuzungspfade des Fahrzeugmittelpunkts zeigen ein breites Spektrum an gefahrenen Kurvenradien.

Eine Erweiterung der Zeitreserven [37] auf Kreuzungssituationen mit mehreren Verkehrsteilnehmern wird von Tamke et al. [72] vorgeschlagen. In einer seiner Fallstudien, dem Abbiegeassistenten, verwendet er eine deterministische Bewegungsprognose für beide betrachtete Fahrzeuge. Die Prognose des Abbiegemanövers des Ego-Fahrzeugs erfolgt auf einem definierten Kreuzungspfad (siehe Abb. 2.4b) und nimmt eine konstante Längsbeschleunigung als Inputgröße des Systemfahrzeugs an. Die Bewegung des entgegenkommenden Fahrzeugs wird über einen Extrapolationsansatz des aktuellen Fahrzeugzustandes prognostiziert. Die Kritikalität einer prognostizierten Kollision wird über die Zeitreserven zu den letztmöglichen Kollisionsvermeidungsmanövern, wie Bremsen, Lenken und Gas geben, bewertet. Eine nähere Betrachtung dieses Ansatzes erfolgt im Abschnitt 3.6.1.

In der Arbeit von Hayashi et al. [32] werden Hidden-Markov-Modelle zur Erkennung von anormalen Verhalten eines Fahrers in Kreuzungssituationen eingesetzt. Zeitreserven werden in dieser Arbeit als Indikatoren für die Kritikalität und somit für ein anomales Verhalten in einem Modell eingesetzt.

In der Arbeit von Althoff et al. [2] werden geplante Trajektorien eines autonomen Fahrzeugs auf Gefahr bewertet. Dazu wird die Bewegung des Verkehrsumfelds vorhergesagt, einschließlich einer Interaktion zwischen den Verkehrsteilnehmern. Die Prognose für ein autonom fahrendes Fahrzeug ist deutlich einfacher, als für ein Fahrzeug, das durch einen Menschen gesteuert wird. Dabei werden prognostizierte

Trajektorien eines autonomen Fahrzeugs aus der Trajektorienplanung entnommen.

Ein Modell zur Schätzung der Gefahr in beliebigen Verkehrssituationen wird von Broadhurst et al. [14] vorgeschlagen. Über Monte-Carlo-Simulation werden anhand eines Bewegungsmodells verschiedene Aktionen eines Fahrers als Bewegungshypothesen durchgespielt. Die Kombination der Aktionsfolgen der Verkehrsteilnehmer bilden mögliche zukünftige Szenarien und werden auf Kritikalität geprüft. Die Aktionsfolgen, die einer definierten Manöverklasse z.B. Überholmanöver, Abbiegemanöver ähneln, werden gegenüber anderen Manövern mit höherer Wahrscheinlichkeit gewichtet. Mit diesem Mechanismus werden die typischen Manöver gegenüber chaotischen Aktionsfolgen, z.B. Schlangenlinien, hervorgehoben. Basierend auf diesem Ansatz gibt es eine Erweiterung, die von Eidehall und Petersson [22] vorgeschlagen wurde. Ihr Ansatz berücksichtigt unter anderem eine gegenseitige Sichtbarkeit der Verkehrsteilnehmer bei der Gefahrenschätzung.

Aoude et al. [4] suchen mit Hilfe eines Rapidly-Exploring Random Trees (RRT) [51] nach einem bestmöglichen Ausweichpfad für das Systemfahrzeug. Das Systemfahrzeug, das über das aktive Sicherheitssystem verfügt, ist ihrer Annahme nach sicher, wenn es einen kollisionsfreien Ausweichpfad gibt. Bei der Suche nach dem bestmöglichen Ausweichpfad werden die erkannten Fahrerabsichten [3] der anderen Verkehrsteilnehmer berücksichtigt.

Das Gefahrenpotential hängt nach Brännström et al. [12] von der Möglichkeit eines Fahrers ab durch eins der drei festgelegten Manöver, Lenken, Bremsen, Beschleunigen, einem Objekt auszuweichen. Die kinematischen Grenzen eines Manövers werden aus der typischen Fahrweise bestimmt, anders als in den meisten Ansätzen durch extreme Ausweichmanöver. Eine gekoppelte Längs- und Querdynamik für das Ausweichen wird dabei nicht betrachtet. Zusätzlich wird die Bewegungsprognose der Objekt-Fahrzeuge deterministisch bestimmt, d.h. nur eine Bewegungshypothese. Die Vorteile des Ansatzes liegen nach Brännström mit 0,001 s pro ausgewertete Situation in der Recheneffizienz, die sich somit hervorragend für den Einsatz in Fahrzeug eignet. Ein weiteres wichtiges Kriterium ist die geringe Anzahl von Falschauslösungen. Zudem ist es eines der wenigen Ansätze, die auf Basis einer großen Datenmenge aus dem Realverkehr ausgewertet wurden.

Die beschriebenen Ansätze basieren auf einem Bewegungsmodell, mit dem die Bewegungsmuster für die Prognose erzeugt werden können. In den Kapiteln 4 und 5 werden Mustererkennungsalgorithmen zur Prognose von Fahrzeugbewegungen angewendet. Die beobachteten Kreuzungstrajektorien zwischen zwei Fahrzeugen werden als Erfahrungen über das Fahrerverhalten verwendet. Während der Fahrt wird die erzeugte Wissensbasis nach ähnlichen Trajektorien bzw. Situationen abgefragt. Die Fortsetzung der Bewegungsmuster aus einer ähnlichen Situation aus der Wissensdatenbank wird als Prognose für die aktuelle Situation verwendet. Eine Bewegungsprognose mittels Mustererkennung wird in dieser Arbeit in den Kapiteln 4 und 5 diskutiert.

Modellbasierter Handlungsspielraum

3.1 Zielstellung

Diese Arbeit strebt einen Ansatz zur Erkennung von kritischen Situationen mit entgegenkommenden Fahrzeugen an. Dazu gehört eine zuverlässige Bewegungsprognose, sowohl des eigenen Systemfahrzeugs als auch des Entgegenkommers. Die Herausforderung ist der Umgang mit Unsicherheiten bezüglich der Fahrerabsichten. Beim Streben zu einer möglichst frühzeitigen und zuverlässigen Erkennung von kritischen Situationen stößt man auf ein Dilemma. Solange ein Fahrer in einer Situation theoretisch noch die Möglichkeit hätte einen Unfall zu vermeiden, ist es eine Herausforderung aus der Perspektive eines Dritten vorherzusagen, dass der Fahrer es nicht tun wird. Schafft eine Situationserkennung alle Hinweise auf eine kritische Situation richtig zu deuten, erst dann kann ein Hinweis an einen Fahrer gerechtfertigt sein. Eine Beispielsituation auf einer vierarmigen Kreuzung, für die der Kreuzungsassistent (siehe Abb.1.4a) ausgelegt ist: Der Fahrer \mathcal{A} möchte auf der Kreuzung nach links abbiegen, übersieht das entgegenkommende Fahrzeug \mathcal{B} und nimmt ihm die Vorfahrt. Dabei stellt sich die Frage: Wie erkennt man möglichst frühzeitig, dass der Abbieger die Vorfahrt nimmt? Dieses Beispiel soll das Dilemma unterstreichen.

Eine Beobachtung des Fahrers und seiner Aktivitäten in Bezug auf Aufmerksamkeit oder vitalen Zustand wäre von Vorteil, denn diese bilden zusammen eine häufige Unfallursache. Ein derartiges Assistenzsystem bietet die Daimler AG unter dem Produktnamen Attention Assist© an. Dieses System beobachtet den Fahrstil des Fahrers und weist bei bestimmten Anzeichen für Müdigkeit den Fahrer durch das Einblenden einer Kaffeetasse auf eine notwendige Pause hin. Es ist ein präventives System und warnt bei einer häufigen Ursache von kritischen Situationen. Unser Fokus liegt auf Erkennung von kritischen Situationen mit beliebiger Ursache, die sich ausschließlich aus dem Bewegungszustand der Fahrzeuge und derer relativen Position ableiten lässt.

Bei der Bewegungsprognose liegt hier der Schwerpunkt nicht auf der Erkennung einer

”wahren” Absicht des Fahrers, sondern auf einer Analyse aller seiner Optionen zum Handeln in einer Situation. Zusätzlich soll ein Maß für die Kritikalität einer Situation betrachtet werden, das eine Warnung an einen Fahrer nachvollziehbar rechtfertigt.

Der Ausgang für unseren Ansatz einer Gefahrenschätzung ist ein Versuchsträger der Daimler AG. Über die Onboard-Sensorik des Versuchsträgers, Stereokamera und Radar, werden die Position und der Bewegungszustand eines entgegenkommenden Fahrzeugs erfasst. Zusätzliche Informationen über die Umwelt, wie der befahrbare Freiraum werden nicht verwendet. Damit beschränkt sich der Fokus der Sensorik ausschließlich auf das entgegenkommende Fahrzeug. Ein Rechenzyklus von 0,02 s steht der Situationsanalyse für die Gefahrenschätzung zu Verfügung. Die Rate zur Schätzung einer Situation wurde als notwendig erachtet, um möglichst schnell auf Änderungen in einer Situation zu reagieren. Mit einer Warnung bei kritischen Situationen lässt sich ein Kreuzungsassistent [77] realisieren.

In den Arbeiten von Broadhurst [14] wird ein Baum von möglichen Aktionen der Verkehrsteilnehmer aufgestellt und dieser zur Gefahrenschätzung betrachtet. Eine ähnliche Technik ist bereits unter dem Namen Rapidly-exploring Random Trees (RRT) [51] aus dem Bereich Pfadplanung in der Robotik bekannt. In der Abb. 3.1 soll eine Suche nach einer kollisionsfreien Trajektorie innerhalb einer stationären Umgebung veranschaulicht werden. Eine Kette von fett markierten Rechtecken hebt eine gefundene kollisionsfreie Trajektorie [64] hervor. Diese Kette besteht aus einer Folge von gesampelten Aktionen eines Fahrers, die kollisionsfrei an allen Hindernissen vorbei führt. Jeder der Rechtecke repräsentiert den Endzustand einer kollisionsfreien Aktion mit einer festen Dauer und entspricht einem Knoten des Rapidly-exploring-Random-Trees. Diese Technik verwendet Broadhurst zur Berechnung einer Gefahren-




Abbildung 3.1: Rapidly-exploring Random Trees zur Suche nach einer kollisionsfreien Trajektorie (blaue Rechtecke) um die Hindernisse.

wahrscheinlichkeit und stellt einen Zusammenhang zur Monte-Carlo-Simulation [58] her. Mit der Monte-Carlo-Simulation wird ein Integral numerisch approximiert, das anhand von Fahrerreaktionen eine Gefahrenwahrscheinlichkeit bestimmt. Für mehrere Fahrzeuge werden auf diese Art kombinatorisch die zukünftigen Aktionen auf Kollision analysiert. Diese Ansätze setzen eine digitale Karte mit allen stationären Hindernissen voraus. Bisher wurden diese Ansätze nicht im realen Verkehr getestet und nur in einer Simulation betrachtet.

Das Modells zur Gefahrenschätzung von Broadhurst et al. [14] erweitern Eidehall et al. [22] um eine Optimierung der Sampling-Technik mit zusätzlichem A-priori-Wissen über die gegenseitige Sichtbarkeit der Fahrer. Bei der gegenseitigen Sichtbarkeit werden Fahrzeuge außerhalb der Fahrtrichtung kritischer eingestuft als innerhalb. Die Erzeugung von Bewegungsmustern zur Prognose erfolgt anhand einer Gewichtungsfunktion, die auch die A-priori-Wahrscheinlichkeitsverteilung definiert. Anhand dieser Gewichtungsfunktion werden Fahrerreaktionen, die das Fahrzeugs von einer Referenzspur weiter entfernen, als weniger wahrscheinlich gewichtet. Damit werden mögliche Abbiegemanöver unwahrscheinlicher, obwohl diese für eine Prognose in Kreuzungssituationen erforderlich sind. Die zukünftige Bewegung des Ego-Fahrzeugs wird aus der Spurinformaton in deterministischer Form berechnet. Damit wird die Unsicherheit bezüglich der zu assistierenden Fahrerabsichten erst gar nicht betrachtet. Für die wahrscheinlichsten Bewegungshypothesen mit einer Kollision wird eine Zeitreserve Time-To-Collision [80] [37] berechnet, die die verbliebene Zeit bis zur Kollision auf Basis einer Bewegungshypothese darstellt. Diese Zeitreserve fungiert als ein Maß für die Kritikalität der Situation und wird zum Triggern von Warnungen eingesetzt. Weitere Zeitreserven werden im Abschnitt 3.6.1 betrachtet.

Der Ansatz von Botsch et al. [50] betrachtet alle Ausweichaktionen der Fahrzeuge in Kombination. Bei den Aktionen handelt es sich unter anderem um Manöver im physikalischen Grenzbereich, die einem Fahrer zugetraut werden. Die Nichtexistenz kollisionsfreier Ausweichmanöver ist ein Indiz für eine kritische Situation. Ein Filter in Form eines Klassifikators erkennt effizient relative Fahrzeugzustände, in denen beide Fahrzeug nicht mehr aneinander vorbei fahren können. Die Zustände, in denen die Fahrzeuge aneinander vorbei kommen, werden als unkritisch klassifiziert und nicht weiter analysiert. Für die kritischen Situationen wird eine über alle Hypothesenpaare gemittelte Zeitreserve Time-To-Collision berechnet.

Die Abb. 3.2 visualisiert für eine Konstellation zweier Fahrzeuge \mathcal{A} und \mathcal{B} unterschiedliche Aktionshypothesen in Kombination mit einer Kollisionsüberprüfung. In der Ausgangssituation biegen beide Fahrzeuge nach links ab. Pro Fahrzeug wurden vier zukünftige Aktionen für die nächsten 2 s betrachtet. Jede Spalte repräsentiert eine von vier betrachteten Aktionen $\mathbf{u}_{\mathcal{A}}^{(1)}$, $\mathbf{u}_{\mathcal{A}}^{(2)}$, $\mathbf{u}_{\mathcal{A}}^{(3)}$ und $\mathbf{u}_{\mathcal{A}}^{(4)}$ des roten Fahrzeugs \mathcal{A} . Die Zeilen repräsentieren eine von vier Aktionen $\mathbf{u}_{\mathcal{B}}^{(1)}$, $\mathbf{u}_{\mathcal{B}}^{(2)}$, $\mathbf{u}_{\mathcal{B}}^{(3)}$ und $\mathbf{u}_{\mathcal{B}}^{(4)}$ des blauen Fahrzeugs \mathcal{B} . Somit ist jede Zelle der 4x4-Matrix eine mögliche Kombination der

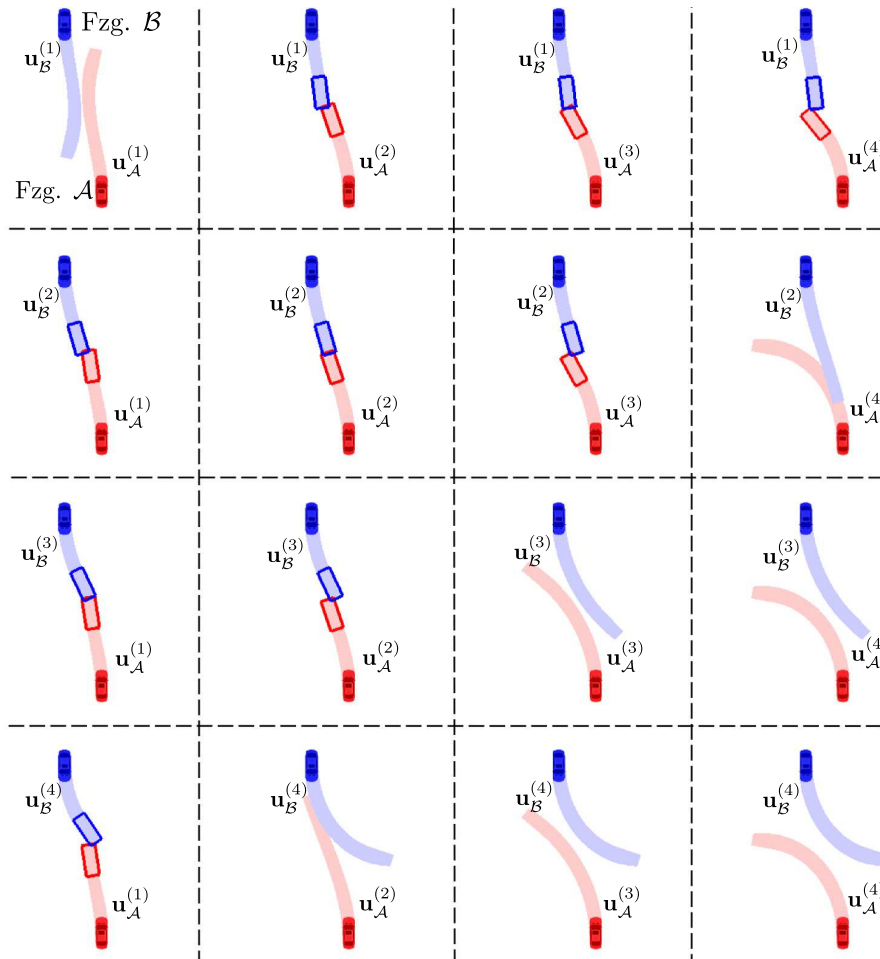


Abbildung 3.2: Eine Matrix aus möglichen Aktionen (hier nur Lenkmanöver) zweier Fahrzeuge. Unterschiedliche Aktionen der Fahrer werden durch Fahrschläuche mit einer Dauer von 2 s dargestellt. Prognostizierte Kollisionen werden durch Rechtecke am Ende eines Fahrschlauchs markiert.

Bewegungshypothesen beider Fahrer. Die Bewegung ist dargestellt in Form eines Fahrschlauches. Eine Kollision zwischen den Fahrzeugen wird über Rechtecke, die die Fahrzeug-Korpora darstellen, hervorgehoben. Mit einem Gegenlenkmanöver, das durch das Aktionspaar $(u_A^{(1)}, u_B^{(1)})$ oben links in der Abbildung dargestellt ist, hätten beide Fahrer in dieser Situation die Möglichkeit ihre Absicht nach links abzubiegen zu ändern und rechts kollisionsfrei aneinander vorbeifahren. Entlang der Diagonalen, von unten links bis oben rechts in der Abbildung, befinden sich Aktionspaare, die zu einer Kollision führen. Unten rechts in der Matrix lenken beide Fahrer nach links und biegen voreinander ab. Dieses entspricht einem sogenannten amerikanischen Abbiegen. Diese Darstellung soll eine kombinatorische Vielfalt von möglichen Ausgängen einer Situation andeuten. Unter der Annahme, dass beide Fahrzeug die

Situation kollisionsfrei überstehen, deutet die Analyse aufgrund einer Mehrzahl von kollisionsfreien Linksabbiegeaktionen darauf hin, dass beide Fahrzeuge voreinander links abbiegen.

Beobachtungen des Alltagsverkehrs zeigen, dass sich der Fahrstil unter den Fahrern einerseits unterscheiden mag, andererseits liegt die typische Fahrweise, die meistens unkritisch ist, weit unterhalb des physikalischen Grenzbereichs. Im Abschnitt 3.2.1 soll eine Messreihe dieses belegen. Damit wird an dieser Stelle angenommen, dass ein Fahrer niemals eine Vollbremsung eines anderen Fahrers als eine unkritische Aktion z.B. zur Gewährung der Vorfahrt akzeptiert. Deshalb ist es wichtig die physikalischen Größen, wie Beschleunigung und Lenkrate, während einer ungefährlichen Interaktion zwischen mehreren Fahrern zu beobachten und diese Beobachtungen in Form von Aktionsgrenzen [12] zu definieren. Derartige Aktionsgrenzen lassen sich als Parameter zum Filtern von unkritischen Aktionen einsetzen. Das Ziel des Filterns wäre Bewegungshypothesen zu filtern, die der Fahrer theoretisch, ohne dabei andere Verkehrsteilnehmer zu verunsichern, durchführen könnte. Ob er es dann schlussendlich tun wird oder nicht, soll hier aufgrund der hohen Komplexität einer erforderlichen Langzeitprognose der Fahrerabsicht nicht geschätzt werden.

Bei Betrachtung eines Handlungsraums zwischen zwei Fahrzeugen wird ein Modell einer elementaren Aktion herangezogen. Anhand dieser elementaren Aktionen sollen mögliche Vorbeifahrten an einem anderen Fahrzeug untersucht werden. Dabei sollen die Aktionen über die Aktionsgrenzen gefiltert werden. Extreme Aktionen im physikalischen Grenzbereich werden als Handlungsoptionen ausgeschlossen. Mit der Annahme die genauen Absichten der Fahrer *nicht* zu kennen, werden alle unkritischen Aktionen der Fahrer als gleichwahrscheinlich betrachtet. Die Betrachtung eines Raumes aus Aktionen soll eine Analyse des gesamt möglichen Verhaltens eines Fahrers in einer Situation ermöglichen. Bei der Bestimmung der Gefahrenschätzung werden alle Aktionen beider Fahrer in Kombination auf Kollision geprüft. Solange beide Fahrer über genügend Aktionen zum Vorbeifahren verfügen, wird diese Situation von uns als unkritisch eingestuft. Nach dieser Idee soll ein Modell der Gefahrenwahrscheinlichkeit in dieser Arbeit abgeleitet werden.

Im Kreuzungsverkehr lässt sich beobachten, dass die Fahrzeuge stets beim Abbiegen einen Abstand zwischen einander einhalten. Dieser Abstand bestimmt eine subjektive Grenze des Wohlfühlens. Auch außerhalb des Verkehrs werden im Alltag zwischen den Menschen unterschiedliche Abstände beobachtet. Diese Abstände sind ein Teil der nonverbalen Kommunikation [31] und hängen unter anderem von der Beziehungsart der Menschen ab. Der Abstand zu vertrauten Personen, wie der Familie, ist während einer Diskussion geringer als zu einem Bekannten. Der Abstand zwischen zwei Menschen bestimmt auch den Bewegungsfreiraum des Menschen. Überträgt man diese Erkenntnis auf die Fahrer, dann ist der Beziehungsstatus zwischen den Fahrern meistens fremder Natur und der Bewegungsfreiraum muss bei Fahrzeugen anders betrachtet werden. Die Bewegungsfreiheit ist auf die Kinematik des Fahrzeugs reduziert, d.h. der Fahrer kann sich nicht in beliebige Richtung bewegen. Im Nahbe-

reich lässt sich der Bewegungsfreiraum über elementare Aktionen der Fahrer prüfen, ob die Fahrzeuge einander kollisionsfrei passieren können. Der Handlungsspielraum der Fahrer repräsentiert die Bewegungsfreiheit der Fahrer. Ähnlich zu den sozialen Abständen in der Proxemik soll in diesem Ansatz im Hinblick auf subjektiv angenehm empfundenen freien Handlungsspielraum im Kreuzungsbereich zwischen zwei Fahrern nachgewiesen werden. Später fungiert dieser freie Handlungsspielraum, der in dieser Arbeit den Namen Feel-Safe-Zone bekommt, als ein Kriterium für die Erkennung einer kritischen Kreuzungssituation.

3.2 Elementare Aktion

Eine Reaktion eines Fahrers beim Umfahren eines Hindernisses ist von elementarer Natur: der Fahrer verzögert, dreht am Lenkrad oder tut beides zugleich. Bei zwei aufeinander zufahrenden Fahrzeuge visualisiert die Abb. 3.2 ein Spektrum von elementaren Lenkmanövern. Ein Teil dieser Manöverpaare zeigt letztmögliche Vorbeifahrmanöver der Fahrer auf. Diese sind ausreichend, um nachzuweisen, dass beide Fahrer in der Lage wären, aneinander vorbei zu fahren. Für die Schätzung einer Gefahrenwahrscheinlich ausschließlich zwischen zwei Fahrzeuge reichen diese elementaren Manöver aus.

Eine elementare Aktion ist definiert als eine Kombination eines Lenkeingriffs und einer konstanten Längsbeschleunigung, die einer Betätigung des Gas- oder Bremspedals entspricht. Damit sollen unter anderem Verzögerungen in Kombination mit dem Abbiegeverhalten als Bewegungshypothese betrachtet werden.

Der kinematische Fahrzeugzustand zum Zeitpunkt t_0 besteht aus einer Position (x_0, y_0) auf einer zweidimensionalen Ebene (der Straße) bezüglich eines Koordinatensystems, einer Fahrzeugorientierung ψ_0 , einer absoluten Geschwindigkeit v_0 und dem Radlenkwinkel δ_0 . Die Berechnung des Zustands $\mathbf{x}_0 = (x_0, y_0, v_0, \psi_0, \delta_0)$ erfolgt über Tracking-Verfahren und wird hier als gegeben angenommen. Der Zustand ist ein Startpunkt für eine Bewegungsprognose. Eine Bewegungshypothese nach der elementaren Aktion setzt sich aus einem konstanten Aktionstupel aus Längsbeschleunigung a_x




Abbildung 3.3: Die kinematischen Größen eines Einspurmodells.

und Radlenkwinkelgeschwindigkeit $\dot{\delta}$ zusammen

$$\mathbf{u} = \begin{pmatrix} u_1 \\ u_2 \end{pmatrix} = \begin{pmatrix} a_x \\ \dot{\delta} \end{pmatrix}. \quad (3.1)$$

Die Integration der Bewegung erfolgt auf Basis des Einspurmodells [27], [59]. Beim Einspurmodell werden die Räder auf einer Achse zu einem Rad zusammengefasst, siehe Abb. 3.3. Die Radlenkwinkelgeschwindigkeit als Aktionselement ermöglicht die Berücksichtigung eines Wechsels des Fahrkurses. Die Fahrtrichtung ist durch den Radlenkwinkel δ_0 vorgegeben. Dieser Wechsel der Fahrtrichtung entspricht der natürlichen Fahrweise eines Fahrers, die sich unter anderem durch leichte Schlenkermäner (S-Kurven) auszeichnet. Das um die Radlenkwinkelgeschwindigkeit erweiterte Einspurmodell ergibt dann:

$$\dot{\mathbf{x}}(t) = f(\mathbf{x}, \mathbf{u}, t) = \begin{pmatrix} \dot{x}(t) \\ \dot{y}(t) \\ \dot{v}(t) \\ \dot{\psi}(t) \\ \dot{\delta}(t) \end{pmatrix} = \begin{pmatrix} v(t) \cos \psi(t) \\ v(t) \sin \psi(t) \\ u_1 \\ \delta(t) v(t) (L + v(t)^2 \tau)^{-1} \\ u_2 \end{pmatrix}, \quad (3.2)$$

wobei L der Radstand und τ der Eigenlenkgradient sind. Die Position (x, y) des Fahrzeugs ist bezüglich des Mittelpunktes auf der Hinterachse angegeben. Mit Hilfe einer Integration (siehe Abschnitt 3.5) eines Aktionsvektors \mathbf{u} über den Prognosehorizont lässt sich die Bewegung in Form einer Trajektorie berechnen.

Bei der Integration eines Bremsengriffs soll eine Untergrenze in der Geschwindigkeit das Rückwärtsfahren auf Kreuzungen verhindern. Beim Unterschreiten von $v_{min} = 0$ entspricht die Geschwindigkeit Null und das Fahrzeug bleibt stehen

$$v(t) = \begin{cases} v(t) & v(t) \geq v_{min} \\ v_{min} & \text{sonst} \end{cases}. \quad (3.3)$$

Analog gibt es bei der Integration des Radlenkwinkels eine physikalische Obergrenze, die durch den Wendekreis eines Fahrzeugs begrenzt ist. Die Lenkwinkel-Grenze δ_{max} gilt sowohl für Links- als auch für Rechtsabbiegen

$$\delta(t) = \begin{cases} \delta(t) & |\delta(t)| \leq \delta_{max} \\ \text{sgn}(\delta(t)) \delta_{max} & \text{sonst} \end{cases}. \quad (3.4)$$

3.2.1 Handlungsgrenzen

Eine Situation wird als kritisch eingestuft, wenn der Fahrer gezwungen ist, extreme Ausweichmanöver auf ein anderes Fahrzeug durchzuführen. Was sind extreme

Ausweichmanöver und wo liegen die Grenzen zur unkritischen Fahrweise? Unsere Annahme ist, dass die kritischen Manöver außerhalb der typischen Fahrweise liegen. In diesem Abschnitt wird ein Ansatz zur Erfassung von typischen Handlungsgrenzen während einer Interaktion mit einem anderem Fahrzeug im Alltagsverkehr betrachtet. Die Basis dafür ist eine Messreihe eines Fahrers oder einer Fahrergruppe mit üblichem Fahrstil, d.h. ohne extreme Lenk- und Bremsenriffe, Kreuzungen auf unterschiedliche Art zu überqueren. Der Fahrstil eines Fahrers wird in kinematischen Größen wie Radlenkwinkelgeschwindigkeit $\dot{\delta}$, Radlenkwinkel δ , absolute Geschwindigkeit v , Längsbeschleunigung a_x und Querschleunigung a_y in Form von Trajektorien gemessen. Jeder Zustand dieser Trajektorien liegt demnach im Bereich der Handlungsgrenzen. Das Ziel soll sein, den kinematischen Raum auf Intervalle einzugrenzen. Diese Grenzen fallen fahrerindividuell aus. Über eine hinreichend große Messreihe von Abbiegemanövern an Kreuzungen werden die Handlungsgrenzen empirisch bestimmt.

Zur Vereinfachung wird der Bereich der Fliehkräfte beim Abbiegen nach rechts und links als äquivalent angenommen. Deshalb soll in unserem Fall bei der Querschleunigung nur der Betrag $|a_y|$ betrachtet werden. Um die gemessenen Beschleunigungstupel als Grenzen des Fahrerfahrstils zu erfassen, werden die Tupeln aus dem Betrag der Querschleunigung und Längsbeschleunigung über ein Polygon $q(a_x)$ (siehe Abb. 3.4) auf der Achse der Längsbeschleunigung eingehüllt. Das Bestimmen der einhüllenden Stützstellen erfolgt durch das Suchen nach dem Maximum aus $a_y^{(i)}$ -Messungen, deren $a_x^{(i)}$ innerhalb einer ε -Umgebung um das a_x liegen

$$a_{y,max} = q(a_x) = \max \left\{ |a_y^{(i)}| \in \mathbb{R}_{\geq 0} \mid |a_x - a_x^{(i)}| < \varepsilon \right\}. \quad (3.5)$$

Die Größe von ε sollte so gewählt werden, dass die Datenmenge innerhalb dieser Umgebung repräsentativ genug ist. Weiterhin müssen die Ausreißer bzw. Falschmessungen gefiltert werden, weil diese die Handlungsgrenzen verfälschen würden.

Eine Messreihe von Beschleunigungstupeln (siehe Abb. 3.4a) während unterschiedlicher Kreuzungsmanöver liegt relativ weit innerhalb des Kammschen Kreises. Damit sondert sich das typische Verhalten der Fahrer deutlich von den physikalischen Grenzen des stabilen Fahrens ab. Bei einem Haftreibungskoeffizient eines Reifens zum trockenen Asphalt von $\mu_H = 1$ entspricht die Fliehkraft, die auf den Fahrer einwirkt, der g -Kraft mit einer g -Beschleunigung von $\approx 9,81 \text{ m/s}^2$. Die maximal auftretende der Radlenkwinkelgeschwindigkeit wird analog zu der Querschleunigung in Betragsform $|\dot{\delta}|$ betrachtet. Die Ober- und Untergrenze der Längsbeschleunigung ($a_{x,min}, a_{x,max}$) werden ebenfalls aus den Messungen ermittelt. Der maximal auftretende Radlenkwinkel des Fahrzeugs wird aus der Querschleunigung sowie dem Wendekreis R_{min} und dem Eigenlenkgradient τ bestimmt.

Die Tabelle 3.1 fasst alle kinematischen Größen mit ihren Handlungsgrenzen zusammen. Mit diesen Grenzen können beliebige Bewegungen in Form von Trajektorien

gefiltert werden, die außerhalb der normalen Fahrweise liegen.

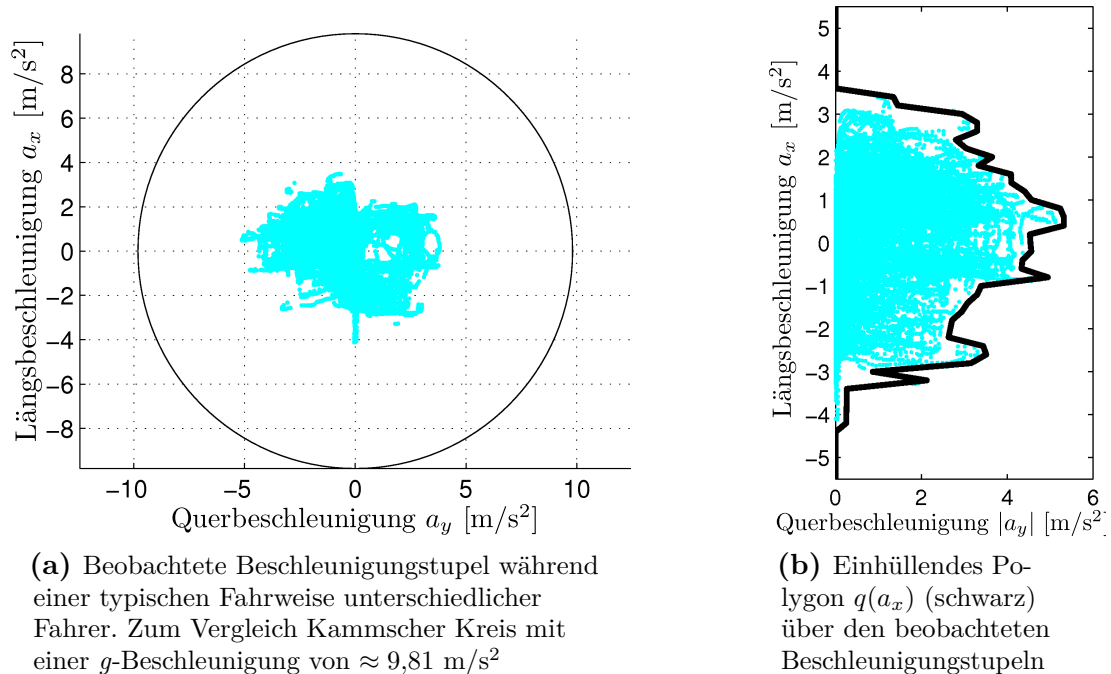


Abbildung 3.4: Handlungsgrenzen aus einer Messreihe von Beschleunigungstupeln (a_x, a_y) .

Tabelle 3.1: Physikalische Schwellen beschreiben die Handlungsgrenzen aus einer unkritischen Fahrweise eines oder mehrerer Fahrer.

Querdynamik	Längsdynamik
Querbeschleunigung $a_{y,max} = q(a_x)$	Max. Beschleunigung $a_{x,max} = \max(a_x^{(i)})$
Lenkrate $\dot{\delta}_{max} = \max(\dot{\delta}^{(i)})$	Max. Verzögerung $a_{x,min} = \min(a_x^{(i)})$

Die Handlungsgrenzen ermöglichen das unkritische Fahrverhalten einer Personengruppe zu berücksichtigen. In der Praxis können, aufgrund fehlender Kommunikation zwischen den Fahrzeugen, die Handlungsgrenzen des einen oder anderen Fahrers nicht vorliegen. Eine Lösung dafür ist stattdessen die Handlungsgrenzen eines Durchschnittsfahrers heranzuziehen. Bei unseren Experimenten im folgenden Kapitel wurde aus einer Reihe von Messungen ein Durchschnittsfahrer ermittelt.

Nur ein Teil aller Aktionsgrößen (3.1) führen zu Manövern, die innerhalb der Handlungsgrenzen liegen. Das Überprüfen einer elementaren Aktion auf die Einhaltung der kinematischen Handlungsgrenzen aus Abschnitt 3.2.1 erfolgt über die Gleichung (3.6). Die Gleichung setzt voraus, dass zum einen die Aktion (u_1, u_2) innerhalb der Grenzen liegt und zum anderen der maximale Betrag der Querbeschleunigung

$a_y^{max} = \max(v(t) \dot{\psi}(t))$ für $t \in I_a$ die Obergrenze $q(u_1)$ nicht überschreitet

$$h(\mathbf{u}, a_y^{max}) := \begin{cases} 1 & |u_2| \leq \dot{\delta}_{max} \wedge a_{x,min} \leq u_1 \leq a_{x,max} \wedge a_y^{max} \leq q(u_1) \\ 0 & \text{sonst} \end{cases} \quad (3.6)$$

Solange die Aktion über das gesamte Prognoseintervall innerhalb der Handlungsgrenzen liegt, gibt die Funktion (3.6) eine 1, sonst 0 zurück.

Die Abb. 3.5 veranschaulicht für drei unterschiedliche Startzustände eines Fahrzeugs eine entsprechende Menge elementarer Aktionen. Die Manöver werden in Form von Fahrschläuchen der Fahrzeuge auf die Straßenebene projiziert. Der zeitliche Horizont der Manöver ist auf 2 s begrenzt. Bei einer Geradeausfahrt mit 12 m/s (siehe Abb. 3.5a) ist der Fächer der möglichen Aktionen eines Fahrers enger als bei einer mit 8 m/s (siehe Abb. 3.5b). Der Grund dafür liegt in der Querbefleunigung, die bei höherer Geschwindigkeit bereits bei kleineren Lenkmanövern ansteigt und somit die Handlungsgrenzen überschreitet. Der Fächer in Abb. 3.5c für ein Fahrzeug in einer Kurvenfahrt mit einem Start-Radlenkwinkel $\dot{\psi}_0 = 0,5$ rad/s zeigt deutlich einen Hang in die Linkskurve. Die Gegenlenkmanöver führen zu einem s-förmigen Pfad des Fahrzeugs, das hier als Option ebenfalls berücksichtigt wird. Eine ausführliche Beschreibung der Sampling-Technik für die dazugehörigen Aktionsgrößen folgt im Abschnitt 3.5. Das Modell einer elementaren Aktion liefert die Basis für die




Abbildung 3.5: Eine Projektion der Fahrschläuche der elementaren Aktionen, die innerhalb der Handlungsgrenzen liegen, auf die Straßenebene. Der zeitliche Horizont der Manöver ist auf 2 s begrenzt.

Bewegungsprognose und die anschließende Schätzung der Gefahr.

3.3 Gefahrenwahrscheinlichkeit

Bei der Gefahrenschätzung in einer Kreuzungssituation werden zwei Fahrzeuge betrachtet, von denen ein Fahrzeug mit \mathcal{A} und das andere mit \mathcal{B} bezeichnet werden. Die Gefahrenschätzung kann als Algorithmus in einem oder beiden Fahrzeugen laufen. Vom Prinzip leitet sich die Gefahrenschätzung aus der Betrachtung des kollisionsfreien Handlungsspielraumes zweier Fahrer ab, wobei die Handlungen, in unserem Fall elementare Aktionen, entsprechend der Handlungsgrenzen gefiltert werden. Zunächst wird jede Aktion als gleich wahrscheinlich angenommen, deshalb wird folgende A-priori-Verteilung im Aktionsraum betrachtet

$$P(\mathbf{u}) = \frac{h(\mathbf{u}, a_y^{max})}{\int h(\mathbf{u}, a_y^{max}) d\mathbf{u}}. \quad (3.7)$$

Es handelt sich hierbei um eine multivariate Gleichverteilung über den Aktionsraum $u_1 = a_x$ und $u_2 = \dot{\delta}$. Mit einer Gleichverteilung werden sowohl Manöver, die zur Kollision führen, als auch kollisionsfreie, als gleich wahrscheinlich angenommen. Bewegt sich ein Fahrzeug außerhalb der Handlungsgrenzen, d.h. bereits der Startzustand liegt außerhalb, dann kann keine A-priori-Verteilung berechnet werden. Der Zustand des Fahrzeugs wäre damit als untypisch dynamisch klassifiziert. Dies ist ein Indiz für eine hektische Fahrweise oder gar ein extremes Ausweichmanöver.

Bei zwei auf die Kreuzung zufahrenden Fahrzeugen wird je Fahrzeug eine A-priori-Verteilung der elementaren Aktionen berechnet. Eine Hypothese $\mathbf{u}_\mathcal{A}$ kombiniert mit einer Hypothese $\mathbf{u}_\mathcal{B}$ bilden einen möglichen Ausgang der Kreuzungssituation, dessen unkorrelierte Verbundwahrscheinlichkeit aus dem Produkt $P(\mathbf{u}_\mathcal{A}) P(\mathbf{u}_\mathcal{B})$ besteht. Jedes Aktionspaar $\mathbf{u}_\mathcal{A}$ und $\mathbf{u}_\mathcal{B}$ in Kombination kann auch zur Kollision beider Fahrzeuge führen. Diese Überprüfung erfolgt mit Hilfe einer Kollisionserkennung, z.B. indem mittels einer Simulation nach einer Kollision gesucht wird. Existiert eine Kollision für das Manöverpaar, dann ist die bedingte Wahrscheinlichkeit $P(C|\mathbf{u}_\mathcal{A}, \mathbf{u}_\mathcal{B}) P(\mathbf{u}_\mathcal{A})$ für das Kollisionsereignis C gleich 1, sonst bei keiner Kollision gleich 0.

Die Gefahrenwahrscheinlichkeit für eine Situation zwischen Fahrzeug \mathcal{A} und Fahrzeug \mathcal{B} wird über alle Aktionsgrößen durch die Randwahrscheinlichkeit beschrieben

$$P(C) = \int_{\Phi_\mathcal{B}} \int_{\Phi_\mathcal{A}} P(C|\mathbf{u}_\mathcal{A}, \mathbf{u}_\mathcal{B}) P(\mathbf{u}_\mathcal{A}) P(\mathbf{u}_\mathcal{B}) d\mathbf{u}_\mathcal{A} d\mathbf{u}_\mathcal{B}, \quad (3.8)$$

wobei Φ_k mit $k = \{\mathcal{A}, \mathcal{B}\}$ den Fahreraktionsraum innerhalb der Handlungsgrenzen darstellt. Dieses Integral kann approximativ über Monte-Carlo-Methoden [60] oder durch die summierte Rechteckregel (Newton-Cotes-Formeln [67]) berechnet werden.

Der Rechenaufwand beim Lösen des Integrals steigt quadratisch mit der Anzahl der gesampelten Aktionsgrößen bei der Monte-Carlo-Methode oder der Stützstellenanzahl bei der summierten Rechteckregel an.

An einem Beispielszenario des amerikanischen Abbiegens wird in Abb. 3.6 ein typischer Verlauf der inkrementellen Berechnung der Gefahrenwahrscheinlich veranschaulicht. Drei Situationen zu unterschiedlichen Zeitpunkten visualisieren zu dem Verlauf die Fahrzeugkonstellationen. Der Verlauf der Sequenz zeigt, dass beide Fahrer immer einer Gefahr ausgesetzt sind, solange die Fahrzeuge aufeinander zufahren. Das Anfangsstadium des beidseitigen Abbiegens ist die gefährlichste Stelle in dem Verlauf. Ungefähr die Hälfte aller möglichen Paarungen der elementaren Manöver beider Fahrzeuge führen in dieser Situation zur Kollision und das entspricht $P(C) = 0,5$. Sobald die Fahrzeuge im Abbiegeprozess sind, fällt die Gefahr stetig ab.

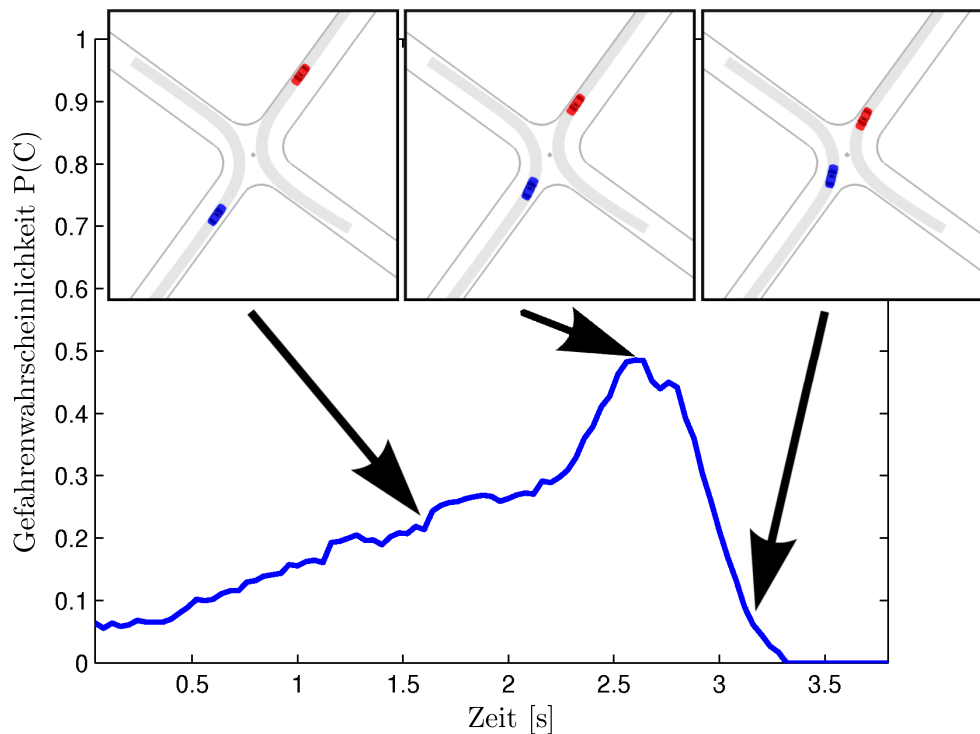


Abbildung 3.6: Signifikante Stellen eines Verlaufs der Gefahrenwahrscheinlichkeit $P(C)$ auf einer Sequenz des amerikanischen Abbiegens. Am Anfang steigt $P(C)$ kontinuierlich an, der kollisionsfreie Handlungsspielraum wird kleiner (links). Das Maximum von $P(C)$ ist die Situation mit den wenigsten kollisionsfreien Handlungsoptionen beider Fahrer (Mitte). Sobald die Fahrzeuge eine Querbeschleunigung aufgebaut haben, sinkt die Gefahr (rechts).

3.4 Feel-Safe-Zone

Im Kreuzungsverkehr kann beim Vorbeifahren zweier Fahrzeuge stets ein Sicherheitsabstand beobachtet werden. Zum Beispiel biegen die Fahrer nicht beliebig knapp voreinander ab. Wann ist das voreinander Abbiegen ungefährlich und wann wird es gefährlich? Mit Hilfe des zuvor aufgestellten Modells einer Gefahrenwahrscheinlichkeit $P(\mathbf{C})$ soll in diesem Abschnitt empirisch eine Grenze für den subjektiven Wohlühlabstand zwischen zwei Fahrern ermittelt werden. Diese Grenze wird auf Basis einer Messreihe von Kreuzungsszenarien bestimmt. Die Fahrer wurden gebeten auf ihre typische Weise die Kreuzung zu überqueren. Die maximale Gefahrenwahrscheinlichkeit repräsentiert eine Grenze für das Minimum an kollisionsfreiem Handlungsspielraum, bei dem sich beide Fahrer sicher gefühlt haben.

Die Bestimmung eines Maximums S_z der Gefahrenwahrscheinlichkeit $P(\mathbf{C})$ aus einer Reihe von zuvor beobachteten unkritischen Kreuzungssituationen legt die Feel-Safe-Zone-Grenze fest

$$S_z = \max (P(\mathbf{C})) . \quad (3.9)$$

Die Feel-Safe-Zone ist definiert als eine Situation zwischen zwei Fahrzeugen, in der die Gefahrenwahrscheinlichkeit $P(\mathbf{C}) < S_z$ die zuvor bestimmte Grenze S_z nicht überschreitet. Unterhalb dieser Grenze haben beide Fahrer genügend Handlungsspielraum, um aneinander vorbei zu fahren.

3.5 Implementierung

Die Details einer softwaretechnischen Umsetzung zur Berechnung der Gefahrenwahrscheinlichkeit soll in diesem Abschnitt vorgestellt werden. Ein effizienter Ansatz zur Kollisionserkennung und eine Approximation der Randwahrscheinlichkeit über alle Aktionen ermöglicht eine Gefahrenschtätzung in wenigen Millisekunden. Die Kollisionserkennung mit den meisten Aufrufen im Algorithmus stellt sich als Flaschenhals dar [29].

Das elementare Handlungsmanöver ist definiert durch eine konstante Aktion über einen begrenzten Prognosehorizont T_H . Der aktuelle Fahrzeugzustand $\mathbf{x}_0 = \mathbf{x}(t_0)$ liefert den Startzustand eines elementaren Handlungsmanövers. Die Berechnung der dazugehörigen Bewegungstrajektorie aus Gleichung (3.2) lässt sich mit dem eulerschen Polygonzugverfahren approximieren. Mit einer Schrittweite von T_s wird eine Folge von Fahrzeugzuständen \mathbf{x}_n mit entsprechenden Zeitpunkten $t_n = t_0 + T_s n$ mit $n = 0, 1, \dots, N$ aufintegriert. Die explizite Euler-Gleichung für ein erweitertes

Einspurmodell (3.2) stellt

$$\mathbf{x}_{n+1} = \mathbf{x}_n + T_s f(\mathbf{x}_n, \mathbf{u}_n, t_n) = \begin{pmatrix} x_n \\ y_n \\ v_n \\ \psi_n \\ \delta_n \end{pmatrix} + T_s \begin{pmatrix} v_n \cos \psi_n \\ v_n \sin \psi_n \\ u_1 \\ \delta_n v_n (L + v_n^2 \tau)^{-1} \\ u_2 \end{pmatrix} \quad (3.10)$$

dar. Das Ergebnis der Integration über das eulersche Polygonzugverfahren ist eine mehrdimensionale Trajektorie $\mathbf{X} = (\mathbf{x}_0, \dots, \mathbf{x}_N)$, die eine Approximation darstellt. Bei der Integration wird ein Manöver bzgl. der Geschwindigkeit (3.3) und des Radlenkwinkels (3.4) begrenzt. Bei dieser Einschränkung darf der Fahrer bis zum Stillstand verzögern und bis zum Erreichen des Wendekreises lenken. Anders ist es bei der Querschleunigung, sobald diese eine empirische Grenze der Handlungsgrenzen (siehe Tabelle 3.1) überschreitet, wird diese aus dem Handlungsspielraum eines Fahrers ausselektiert. Der gesamte Aktionsraum \mathbb{R}^2 soll einer Selektion von möglichen Handlungsoptionen unterzogen werden. Das Resultat liefert eine A-priori-Wahrscheinlichkeitsverteilung für die Manöver, die in einer Situation von dem Fahrer zu erwarten wären.

Mit Hilfe einer Sampling-Technik (Abtasttechnik) soll die kontinuierliche A-priori-Verteilung (3.7) von elementaren Aktionen geschätzt werden. Die Aktionen für Kreuzungsmanöver werden aus den Intervallen $[a_{x,min}, a_{x,max}]$ und $[-\dot{\delta}_{max}, \dot{\delta}_{max}]$ der Handlungsgrenzen gezogen. Die Knotenpunkte eines Gitters fungieren als Samples zur Überprüfung der Bedingung einer maximalen Querschleunigung aus den Handlungsgrenzen (3.6). Die Gitter-Samples bieten eine ideale Gleichverteilung und bieten im Vergleich zu anderen Zufallszahlengeneratoren eine geringere Diskrepanz [49]. Das erste Aktionselement u_1 wird in äquidistante N_{u_1} -Schritte und das zweite u_2 in N_{u_2} -Schritte aufgeteilt. Die Berechnung der Sample-Schrittweiten des ersten Aktionselementes S_{u_1} und des zweiten Aktionselementes S_{u_2} formulieren die folgenden Gleichungen

$$\begin{aligned} S_{u_1} &= \frac{a_{x,max} - a_{x,min}}{N_{u_1} - 1} \\ S_{u_2} &= \frac{2 \dot{\delta}_{max}}{N_{u_2} - 1}. \end{aligned} \quad (3.11)$$

Die N_{u_1} -Samples der Längsbeschleunigung werden iterativ über die äquidistante Schrittweite S_{u_1} berechnet. Analog werden die N_{u_2} -Samples der Radlenkwinkelgeschwindigkeit berechnet

$$\begin{aligned} u_1^{(i)} &= a_{x,min} + i S_{u_1} \text{ mit } i = 0, 1, \dots, N_{u_1} \text{ und} \\ u_2^{(j)} &= -\dot{\delta}_{max} + j S_{u_2} \text{ mit } j = 0, 1, \dots, N_{u_2}. \end{aligned} \quad (3.12)$$

Ein Aktions-Sample setzt sich zusammen aus der Kombination der Samples der Aktionselemente $\mathbf{u} = (u_1^{(i)}, u_2^{(j)})$. Aus dem kartesischen Produkt der Aktionselemente $u_1^{(i)}$ und $u_2^{(j)}$ wird die Menge von möglichen Aktionen generiert

$$\Phi = u_1^{(i)} \times u_2^{(j)}. \quad (3.13)$$

In Abb. 3.7 wird eine Bewegungsprognose während eines Abbiegevorgangs mit Geschwindigkeit $v_0 = 10$ m/s und Radlenkwinkel von $\delta_0 = 0,095$ rad über elementare Aktionen visualisiert. Das Gitter innerhalb des Aktionsraumes (oben rechts) hebt durch schwarze Knoten die zukünftigen Aktionen hervor, die innerhalb der Handlungsgrenzen liegen würden. Die dazugehörigen Bewegungshypothesen eines Fahrzeugs werden in Form einer Trajektorie aus Fahrzeug-Rechtecken bezüglich der Zeit dargestellt. Je größer die Gitterauflösung, desto genauer ist die Schätzung der A-priori-Verteilung des Manöverraumes. Eine höhere Auflösung geht jedoch auch aufgrund der höheren Rechenkomplexität zum Nachteil der Rechenzeit ein.

Eine Diskretisierung des Aktionsraumes über ein Gitter erlaubt die Anwendung einer summierten Rechteckregel (Newton-Cotes-Formeln [67]) zur Approximation einer Randwahrscheinlichkeit (3.8) des Kollisionsereignis \mathbf{C} , bei dem die Fahrzeuge miteinander kollidieren

$$P(\mathbf{C}) \approx \sum_{\Phi_{\mathbf{B}}} \sum_{\Phi_{\mathbf{A}}} P(\mathbf{C}|\mathbf{u}_{\mathbf{A}}, \mathbf{u}_{\mathbf{B}}) P(\mathbf{u}_{\mathbf{A}}) P(\mathbf{u}_{\mathbf{B}}). \quad (3.14)$$

Die bedingte Wahrscheinlichkeit $P(\mathbf{C}|\mathbf{u}_{\mathbf{A}}, \mathbf{u}_{\mathbf{B}})$ steht für ein Kollisionsereignis \mathbf{C} mit dem Manöverpaar $\mathbf{u}_{\mathbf{A}}$ und $\mathbf{u}_{\mathbf{B}}$. Dazu werden die dazugehörigen Trajektorien $X(\mathbf{u}_{\mathbf{A}})$ und $X(\mathbf{u}_{\mathbf{B}})$ linear nach Kollisionen durchgesucht

$$P(\mathbf{C}|\mathbf{u}_{\mathbf{A}}, \mathbf{u}_{\mathbf{B}}) = \begin{cases} 1 & \exists n = 0, 1, \dots, N, P(\mathbf{C}|\mathbf{u}_{\mathbf{A}}, \mathbf{u}_{\mathbf{B}}, t_n) = 1 \\ 0 & \text{sonst.} \end{cases} \quad (3.15)$$

wobei $t_n = t_0 + T_s n$ die diskreten Zeitschritte sind. Die Existenz eines Zeitpunktes, in dem beide Fahrzeuge kollidieren, führt zu dem Ereignis $P(\mathbf{C}|\mathbf{u}_{\mathbf{A}}, \mathbf{u}_{\mathbf{B}}) = 1$. Die Schrittweite T_s hängt von Geschwindigkeit und Abmessungen der Fahrzeuge ab. Bei einer zu großen Schrittweite besteht das Risiko, dass die Fahrzeuge einander überspringen und folglich eine Kollision übersehen wird. Bewegen sich zwei Fahrzeuge mit 60 km/h aufeinander zu, liegen die Sprünge aus der numerischen Integration bei einer Schrittweite von 0,1 s bei $3\bar{3}$ m. Sobald die Fahrzeuge leicht quer aufeinander zufahren, existiert eine hohe Wahrscheinlichkeit, dass eine Kollision übersprungen wird. Zur Berechnung der bedingten Kollisionswahrscheinlichkeit zu einem bestimmten Zeitpunkt $P(\mathbf{C}|\mathbf{u}_{\mathbf{A}}, \mathbf{u}_{\mathbf{B}}, t = n T_s)$ ist eine Überprüfung der Fahrzeugaußenhülle bzw. Bounding Volume [23] auf Kollision erforderlich. Zur Bestimmung der Fahrzeugaußenhülle zum Zeitpunkt t_n werden aus der Bewegungstrajektorien die Position (x_n, y_n) und der Gierwinkel ψ_n sowie die Fahrzeugabmessungen beider Fahrzeuge




Abbildung 3.7: Eine Schar von zukünftigen Bewegungs-Trajektorien eines durch Rechteck dargestellten Fahrzeugs. Die Trajektorien wurden durch elementare Aktionen erzeugt (schwarze Punkte im Aktionsraum oben rechts im Kasten), die innerhalb der Handlungsgrenzen liegen. Der initiale Zustand des Fahrzeugs ist $v_0 = 10$ m/s und $\delta_0 = 0,095$ rad.

herangezogen. Damit lässt sich der Fahrzeugkorpus eindeutig konstruieren.

Der Fahrzeugkorpus wird in dieser Arbeit in einer zweidimensionalen Ebene durch eine Kapsel angenähert werden (siehe Abb. 3.8). Eine Kapsel kann als die Einhüllende von Kreisen entlang eines Segments der Fahrzeug-Längsachse betrachtet werden. Die Endpunkte des Segments und der Radius des Kreises werden so gewählt, dass das Fahrzeugkorpus minimal eingehüllt wird. Die leicht rundliche Form der Front und des Hecks der aktuellen Fahrzeuge (z.B. Mercedes W221) schmiegt sich in die Kapsel form besser ein (siehe Abb. 3.8a) als die weitverbreitete Rechteckform.

Die Kollisionserkennung zwischen zwei Fahrzeugen erfolgt durch das Überprüfen, ob sich die Fahrzeugkapseln überlappen. Die Kapseln überlappen sich, wenn der kürzeste Abstand zwischen den beiden Segmenten die Summe der Radien unterschreitet. Der kürzeste Abstand zwischen zwei Segmenten kann mittels vier Kombinationen von Punkt-zu-Segment-Distanzen berechnet werden, bei jeder möglichen Paarung von je einem Endpunkt des einen Segments zu dem jeweils anderen Segment.

Die Abb. 3.8b veranschaulicht die Punkt-zu-Segment-Distanz $d_{\mathcal{B},f}^A$ zwischen dem vorderen Endpunkt $\mathbf{p}_{\mathcal{B},f}$ des Fahrzeugs \mathcal{B} und dem Segment $\overline{\mathbf{p}_{\mathcal{A},f} \mathbf{p}_{\mathcal{A},b}}$ des Fahrzeugs \mathcal{A} , wobei die Stelle \mathbf{p}_{min} auf dem Segment liegt

$$d_{\mathcal{B},f}^A = \|\mathbf{p}_{min} - \mathbf{p}_{\mathcal{B},f}\|. \quad (3.16)$$

Der Punkt \mathbf{p}_{min} auf der Geraden, die durch das Segment $\mathbf{p}_{\mathcal{A},f}$ verläuft, mit dem kürzesten Abstand zu Punkt $\mathbf{p}_{\mathcal{B},f}$ lässt sich wie folgt berechnen:

$$\mathbf{p}_{min} = \mathbf{p}_{\mathcal{A},b} + \tilde{\lambda}_{min} (\mathbf{p}_{\mathcal{A},f} - \mathbf{p}_{\mathcal{A},b}). \quad (3.17)$$

Dabei gilt es das Skalar λ_{min} auf dem Intervall $[0,1]$ bezüglich des Betrages (3.16) zu minimieren. Eine geschlossene Lösung für λ_{min} gib die Gleichung

$$\lambda_{min} = \frac{(\mathbf{p}_{\mathcal{B},f} - \mathbf{p}_{\mathcal{A},b}) (\mathbf{p}_{\mathcal{A},f} - \mathbf{p}_{\mathcal{A},b})}{\|(\mathbf{p}_{\mathcal{A},f} - \mathbf{p}_{\mathcal{A},b})\|^2}. \quad (3.18)$$

Liegt λ_{min} außerhalb des offenen Intervalls $[0,1]$, dann liegt auch \mathbf{p}_{min} außerhalb des Segments auf der Geraden, die durch das Segment verläuft. Über die Gleichung (3.19) wird λ_{min} auf das Intervall $[0,1]$ beschränkt

$$\tilde{\lambda}_{min} = \begin{cases} 1 & \lambda_{min} > 1 \\ 0 & \lambda_{min} < 0 \\ \lambda_{min} & \text{sonst} \end{cases}. \quad (3.19)$$

Analog werden die drei weiteren Distanzen $d_{\mathcal{B},b}^A, d_{\mathcal{A},f}^B$ und $d_{\mathcal{A},b}^B$ zwischen Punkt- und Segment-Kombinationen berechnet. Die minimale Distanz zwischen den Kapseln ergibt sich aus dem Minimum der vier Punkt-zu-Segment-Distanzen abzüglich der Summe ihrer Radien

$$d_{\mathcal{B}}^A = \min(d_{\mathcal{B},b}^A, d_{\mathcal{B},f}^A, d_{\mathcal{A},f}^B, d_{\mathcal{A},b}^B) - (r_{\mathcal{A}} + r_{\mathcal{B}}). \quad (3.20)$$




Abbildung 3.8: Der Fahrzeugkörper wird durch eine Kapsel mit einem Segment $\overline{\mathbf{p}_{\mathcal{A},f} \mathbf{p}_{\mathcal{A},b}}$ und Radius $r_{\mathcal{A}}$ angenähert (a). Berechnung des kürzesten Abstandes zwischen einem Segment $\overline{\mathbf{p}_{\mathcal{A},f} \mathbf{p}_{\mathcal{A},b}}$ und dem Punkt $\mathbf{p}_{\mathcal{B},f}$ (b).

Ist die Kapsel-Kapsel-Distanz d_B^A kleiner Null, dann überlappen sich die Kapseln und eine Kollision der Fahrzeuge liegt vor.

Die bedingte Wahrscheinlichkeit für das Kollisionsereignis C zum Zeitpunkt nT_s berechnet sich über die Gleichung

$$P(C|\mathbf{u}_A, \mathbf{u}_B, t = nT_s) = \begin{cases} 1 & d_B^A(t) \leq 0 \\ 0 & \text{sonst.} \end{cases} \quad (3.21)$$

wobei $d_B^A(t)$ die Kapseldistanz der Fahrzeuge zum Zeitpunkt t darstellt.

Die für die Auswertung verwendeten Parameter sind in Tabelle 3.2 aufgelistet. Die Handlungsgrenzen wurden aus einer Messreihe von Kreuzungsmanövern bestimmt. Die Beschleunigungstupeln dieser Messreihe wurden in Abb. 3.4b visualisiert. Die Abtastauflösung der Radlenkwinkelgeschwindigkeiten im Intervall $[-0,4;0,4]$ rad/s ist $N_{u_1} = 17$. Dieses entspricht einer Schrittweite von $S_{u_1} = 0,05$ rad/s. Die Längsbeschleunigung wurde in $N_{u_2} = 8$ Schritte auf dem Intervall $[-4;3]$ m/s² mit Schrittweite von $S_{u_2} = 1,0$ m/s² aufgeteilt. Diese empirisch bestimmte Abtastrate hat in unseren Versuchen gereicht, um die Gefahr der Situationen im Stadtverkehr (d.h. bis 60 km/h) hinreichend genau zu berechnen. Eine feinere Auflösung geht in die Rechenkomplexität ein und erhöht somit die Rechenzeit. Es liegt hier ein Problem der Genauigkeit vs. Rechenzeit vor. Die Querschleunigung wurde über ein einhüllendes Polygon, das in Abb. 3.4b visualisiert wird, über die Gleichung (3.5) bestimmt. Der maximale Lenkwinkel einer Mercedes E-Klasse, Modell W211, ist $\delta_{max} = 0,51$ rad. Als Integrationsschrittweite T_s für die Darstellung von elementaren Aktionen wurde 0,04 s gewählt. Diese Diskretisierungsweite reicht zum Erkennen von Kollisionen. Der Prognosehorizont einer elementaren Aktion wird auf $T_H = 2,0$ s festgelegt. Die Geschwindigkeit eines Manövers ist nach unten durch $v_{min} = 0$ m/s begrenzt und nach oben offen $v_{max} = \infty$ m/s. Die Beschränkung der Geschwindigkeit nach oben ist nicht notwendig, da sich bei einer maximalen Längsbeschleunigung von 3 m/s mit einem Prognosehorizont von 2 s eine maximale Geschwindigkeitszunahme von 6 m/s bzw. 21,6 km/h ergibt. Diese Geschwindigkeitszunahme über den kurzen Zeitraum im Stadtverkehr ist realistisch. Auf Basis dieser Implementierung mit den gewählten Parametern werden im nächsten Abschnitt reale Kreuzungssituationen zwischen zwei Fahrern auf Kritikalität bewertet.

Tabelle 3.2: Parametersatz für die Berechnung der Gefahrenwahrscheinlichkeit für Stadtverkehrssituationen bis 60 km/h.

Elementare Abbiegemanöver		
$T_s = 0,04$ s	$T_H = 2,0$ s	$\delta_{max} = 0,51$ rad
$v_{min} = 0$ m/s	$v_{max} = \text{inf}$ m/s	
Handlungsgrenzen		
$\dot{\delta}_{max} = 0,4$ rad/s	$a_{x,min} = -4,0$ m/s ²	$a_{x,max} = 3$ m/s ²
$a_{y,max} = q(a_x)$ m/s ²		
Abtastauflösung des Aktionsraumes		
$N_{u_1} = 17$	$N_{u_2} = 8$	

3.6 Evaluation

Bei der Feel-Safe-Zone geht es darum eine Kreuzungssituation zwischen zwei Fahrzeugen zu klassifizieren, die aus Sicht beider Fahrer sicher ist oder nicht (siehe Abschnitt 3.4). Nach unserem Modell der Gefahrenwahrscheinlichkeit gibt es bei aufeinander zufahrenden Fahrzeugen stets eine Gefahr, d.h. es gibt Paare von elementaren Aktionen, die zur Kollision führen. Damit ist jeder Fahrer beim Vorbeifahren an einem anderen Fahrzeug einer Gefahr ausgesetzt, die sich jetzt mit der Gefahrenwahrscheinlichkeit in jeder Situation messen lässt. Dennoch wird an dieser Stelle postuliert, dass es eine Grenze auf der Skala der Gefahrenwahrscheinlichkeit gibt, bis zu der sich die Fahrer wohlfühlen, bzw. sich beide in einer Feel-Safe-Zone befinden. Oberhalb dieser Gefahrengrenze müsste aus Sicht der Fahrer ein Unsicherheitsgefühl ansteigen, weil die dazugehörigen Situationen extremere Aktionen oder knappere Vorbeifahrmanöver von beiden Fahrern erfordern.

Zur Bestimmung der Grenze der Feel-Safe-Zone auf der Skala der Gefahrenwahrscheinlichkeit wurden 97 unterschiedliche Kreuzungsszenarien zwischen zwei Fahrern aufgezeichnet. Eine Kreuzung auf dem SimCity-Testgelände in der Daimler AG (siehe Abb. 3.9) diente uns als Aufzeichnungsort. Die Messreihe bekommt deshalb den Namen die *SimCity-Messreihe* und kommt im Kapitel 5 auch zum Einsatz. Jedes Kreuzungsszenario zwischen zwei Fahrzeugen beinhaltet je Fahrzeug eine Bewegungstrajektorie. Bei der Kreuzung handelt sich um eine relativ enge vierarmige Kreuzung ohne Ampelanlage mit einem Kurvenradius von 5 m und einer Spurbreite von 3 m. Zwei Versuchsträger, eine Mercedes S-Klasse (Modell W221) und eine Mercedes E-Klasse (Modell W211), ausgerüstet mit hochgenauen Ortungssystemen standen uns für die Aufzeichnung zur Verfügung. Das Ortungssystem fusionierte über ein Kalman-Filter die DGPS-Daten mit einem empfindlichen Inertialsystem. Die Genauigkeit der Position der Fahrzeuge liegt bei bis zu 0,02 m Standardabweichung



Abbildung 3.9: Daimler-Testgelände für Fahrerassistenzsysteme mit aufgezeichneter Kreuzung(a). Eine Kollision mit dem Softcrash-Target auf einer Testgelände-Kreuzung(b). Copyright Daimler AG

in der Position (Orientierung 0,1 Grad, Geschwindigkeit 0,05 m/s, Beschleunigung $0,01 \text{ m/s}^2$). Mit diesen Genauigkeiten werden an dieser Stelle der Arbeit die Messunsicherheiten [30] vernachlässigt, da sie einen vernachlässigbar kleinen Fehler bei der Gefahrenwahrscheinlichkeit hätte. Es gab insgesamt vier Fahrer, die abwechselnd gefahren sind. Dabei sind die Fahrzeuge zeitnah auf die Kreuzung ohne Einflüsse von anderen Verkehrsteilnehmern wie Fußgängern zugefahren und mussten unterschiedliche Kreuzungsmanöver durchführen, von denen jeweils der andere nichts wusste. Jedes Manöver eines einzelnen Fahrzeugs lässt sich in drei Klassen zuordnen, (L)inks, (G)eradeaus und (R)echts. Jeder Fahrer fuhr mit seinem typischen Fahrstil und kommunizierte seine Absichten wie in echten Kreuzungssituationen über einen Blinker. Die aufgezeichneten 97 Kreuzungsszenarien lassen sich in 6 Situationsklassen kategorisieren (siehe Abb. 3.10).

Aus jeder Sequenz wurde die maximale Gefahrenwahrscheinlichkeit ermittelt. Die Aufteilung dieser Maxima bezüglich der Situationsklassen veranschaulicht die Abb. 3.11. Die Situationen mit relativ wenig Handlungsspielraum bzw. einer hohen Gefahren-




Abbildung 3.10: Sechs Situationsklassen, abgekürzt durch die Initialen der Einzelmanöver (LG - Links-Geradeaus), zwischen zwei Fahrzeugen an einer vierarmigen Kreuzung auf der SimCity-Kreuzung in Sindelfingen.

wahrscheinlichkeit wurden unter den Situationsklassen LL, LG, GG und GR beobachtet. Die gefährlichste Situation bei dieser Messreihe wurde beim amerikanischen Abbiegen (LL) beobachtet. Sie entspricht der maximalen Gefahr in einer von den Fahrern als unkritisch empfundenen Situation. Damit bildet dieser Wert auf der Skala der Gefahrenwahrscheinlichkeit $S_z = 0,56$ eine Grenze für die Feel-Safe-Zone. Unter diesem Wert, d.h. $P(C) \leq S_z$, lag für beide Fahrer genügend kollisionsfreier Aktionsraum vor (44% der Aktionspaare sind kollisionsfrei).

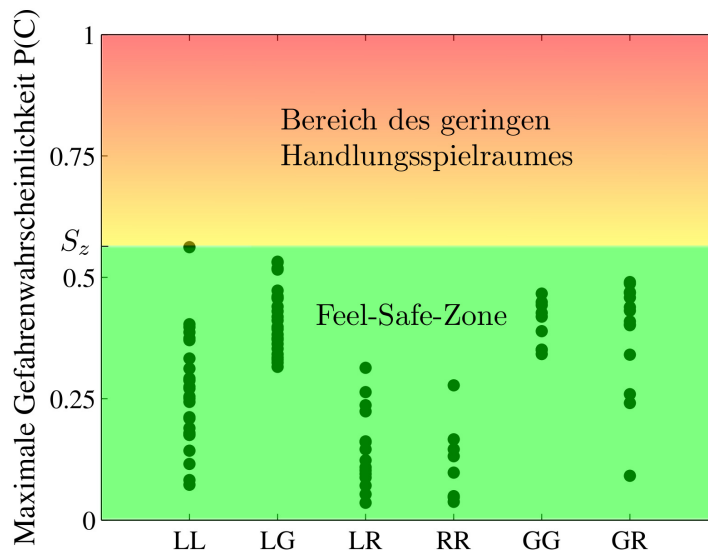


Abbildung 3.11: Kritischste Situationen aus 97 Sequenzen kategorisiert entsprechend der Situationsklassen (LL, LG, ...). Die Skala der Gefahrenwahrscheinlichkeit wird in zwei Teile geteilt, Feel-Safe-Zone (grün) und einen Bereich des geringen Handlungsspielraumes (gelb bis rot).

In Kreuzungssituationen mit ausreichend Abstand zwischen den Fahrzeugen sollte diese Gefahrenwahrscheinlichkeit in den meisten Fällen nicht überschritten werden. Die Gefahrenwahrscheinlichkeit, die oberhalb dieser Grenze $P(C) > S_z$ liegt, müsste auf die Fahrer mit zunehmendem Anstieg kritischer wirken, da den Fahrern weniger Handlungsspielraum zur Verfügung steht.

Besonders kritisch wird eine Situation, wenn die Gefahrenwahrscheinlichkeit auf $P(C) = 1$ ansteigt, dann ist der Handlungsspielraum aus unkritischen Aktionen beider Fahrer ausgeschöpft und es bleiben nur extreme Brems- oder Abbiegemanöver übrig, um eine mögliche Kollision zu vermeiden. Die physikalischen Grenzen der fahrbaren Abbiegemanöver liegen außerhalb des üblichen Fahrstils im Normalverkehr und sind für unseren Ansatz ein Indiz für Anomalie in der Verkehrssituation.

In Form einer Warnkaskade bei drohender Gefahr lassen sich zwei Gefahrenstufen in einem Fahrerassistenzsystem zur Vermeidung von Kollision einsetzen. Die erste Gefahrenstufe wird erreicht, wenn die Feel-Safe-Zone, d.h. $P(C) \leq S_z = 0,56$, ver-

lassen wird und die Zweite beim $P(C) = 1$. Die beiden Warnungen eignen sich als Trigger von akustischen oder visuellen Warnsignalen oder autonomen Eingriffen zur Unterstützung des Fahrers. Die Anwendung dieser Schwelle auf gefährliche Sequenzen soll über Experimente im nächsten Abschnitt vorgestellt werden.

Reale kritische Situationen z.B. durch Unaufmerksamkeit eines Fahrers lassen sich experimentell nur schwer "auf Knopfdruck" nachstellen. Es gibt jedoch eine Möglichkeit künstlich Kollisionsmanöver zwischen zwei Fahrzeugen zu erzeugen. Bei den 24 Links-Geradeaus-Klasse (LG) aus unseren Testdaten biegt ein Fahrzeug nach links ab, nachdem der Entgegenkommende an ihm geradeaus über die Kreuzung vorbei gefahren ist (siehe Abb. 3.10b). Bei der Betrachtung der Pfade beider Fahrzeuge für Manöver der Klasse LG gibt es einen Schnittpunkt (siehe Abb. 3.10b). Die relative Bewegung der Fahrzeuge ist in den unkritischen Szenarien dabei so verlaufen, dass sie kollisionsfrei aneinander vorbei fahren. Mit einem zeitlichen Versatz der Trajektorie des Abbiegers lässt sich die relative Bewegung beider Fahrzeuge so manipulieren, dass Kollision zwischen den Fahrzeugen simuliert wird. Diese Unfall-Sequenzen dienen als Ersatz für Sequenzen mit unaufmerksamen Fahrern. Die Zeit des abbiegenden Fahrzeugs wurde in allen Sequenzen um $\{-1,6 \text{ s}; -2,0 \text{ s}; -2,4 \text{ s}; -2,8 \text{ s}\}$ in die Vergangenheit verschoben. Diese vier Zeitverschiebungen ergeben insgesamt 96 Linksabbiegeklassen (LG) mit Kollision.

Bei der Auswertung dieser Kollision-Sequenzen haben alle die Feel-Safe-Zone, d.h. $P(C) > 0,56$, wie erwartet verlassen und die Gefahrenwahrscheinlichkeit stieg weiter bis $P(C) = 1$ an. Zum Schluss kam es zu einer Kollision zwischen den Fahrzeugen. Der Kollisionszeitpunkt bildet die Referenz, d.h. $t_r = 0$. Relativ zu diesem Referenzzeitpunkt veranschaulicht die Tabelle 3.3 die Zeiten bis zur Kollision (time-to-collision) beim Verlassen der Feel-Safe-Zone und beim Erreichen der maximalen Gefahr von $P(C) = 1$. Die Zeiten mit Standardabweichung sind bezüglich des Kollisionszeitpunkts referenziert. Spätestens bei $P(C) = 1$ hätten beide Fahrer keine Möglichkeit in

Tabelle 3.3: Erkennungszeitpunkte von 96 Vorfahrtsmissachtungen bei einer LG-Situation.

	$P(C) > 0,56$	$P(C) = 1$
time-to-collision	$1,1313 \pm 0,26 \text{ s}$	$0,6288 \pm 0,1697 \text{ s}$

dieser Situation durch normale elementare Manöver aneinander vorbei zu fahren. Der Erkennungszeitpunkt hängt von vielen Faktoren ab, wie z.B. auch von der Größe der Kreuzung. Bei Kreuzungen mit breiteren Spuren kann das Abbiegemanöver früher erkannt werden. Für die Datenaufzeichnung kamen die Fahrzeugmodelle Mercedes Benz E-Klasse mit einer Breite von 2,071 m inklusive der Seitenspiegel und einer Mercedes Benz S-Klasse mit einer Breite von 2,12 m zum Einsatz. Eine geringe Lenkbewegung bei diesen breiten Fahrzeugen auf einer schmalen Kreuzung kann zu

kritischen Situationen führen.

3.6.1 Gefahrenwahrscheinlichkeiten vs. Zeitreserven

Eine Implementierung dieses Ansatzes in einem Versuchsfahrzeug mit Stereokamera und Radarsystemen zur Umgebungserfassung soll in diesem Abschnitt evaluiert werden. Ein Vergleich mit einem Modell der Zeitreserven soll einen Benefit der in dieser Arbeit präsentierten Gefahrenschätzung verdeutlichen. Eine C-Implementierung ermöglicht die Berechnung der Gefahrenwahrscheinlichkeit für zwei Fahrzeuge unterhalb eines 0,020 s Zyklus und weist somit die Eigenschaften eines Echtzeitsystems auf.

Eine verbreitete Art eine Situation auf Gefahren zu bewerten, ist die Berechnung von zeitlichen Reserven [80] bis zu einer Kollision (Time-To-Collision), die einem Fahrer für eine vorhergesagte Kollision bleiben. Die Güte dieser Zeitreserve als ein Maß für die Kritikalität einer Situation hängt stark von der Bewegungsprognose ab. Eine Möglichkeit die Bewegung eines Fahrzeugs für einen kurzen Horizont vorherzusagen, ist die Extrapolation des zuletzt beobachteten Zustandes. Bei der Extrapolation wird die aktuelle Bewegung des Fahrzeugs gleichförmig fortgesetzt. Die Abb. 3.12a veranschaulicht die extrapolierte Fahrzeugbewegung als graue Fahrspur zweier auf eine Kreuzung zufahrender Fahrzeuge. Auf Basis der prognostizierten Trajektorien erfolgt eine lineare Suche nach dem ersten Kollisionszeitpunkt, der in der Abbildung durch zwei Hüllkörper dargestellt wird.

Analog lassen sich Zeitreserven für letztmögliche Kollisionsvermeidungsmanöver [72] (KVM) berechnen. Hierbei wird die für einen Fahrer verbliebene Zeit, um auf die drohende Kollision zu reagieren, berechnet. Drei unterschiedliche Modelle für KVM werden dabei betrachtet: ein maximales Verzögern (B), maximales Beschleunigen (K) oder ein maximaler Lenkeingriff (S). Die Zeit, die der Fahrer bis zum letztmöglichen KVM in Reserve hat, wird als TTB (Time-To-Brake) fürs Bremsen, TTK (Time-To-Kickdown) für Beschleunigung und TTS (Time-To-Steer) für einen Lenkeingriff, bezeichnet. Bei TTS werden Lenkeingriffe nach links und rechts berücksichtigt, wobei der spätere von den beiden in Betracht genommen wird.

Aus den Zeitreserven für die drei KVM wird eine Zeit zum allgemeinen, letztmöglichen Reagieren TTR (Time-To-React) berechnet. Diese setzt sich aus dem Maximum $TTR = \max(TTB, TTK, TTS)$ der Zeitreserven für mögliche KVM zusammen. Die letztmögliche KVM werden in der Abb. 3.12b durch drei farbliche Fahrspuren veranschaulicht. Das KVM durch einen Lenkeingriff nach rechts wird gelb dargestellt, das Bremsen rot und Beschleunigen blau.

Die KVMs, Bremsen, Beschleunigen und Lenken sind extreme Manöver und liegen auf dem Kammschen Kreis bzw. im physikalischen Grenzbereich. Dabei wird eine Querbeschleunigung von $9,81 \text{ m/s}^2$ bei einem Haftreibungskoeffizienten von 1 angenommen.




Abbildung 3.12: Bewegungsprognose über Extrapolation (helle Fahrspur) der Fahrzeugzustände mit einer Kollision nach TTC (a). Zeitreserven (Time-To-Kickdown, Time-To-Brake, Time-To-Steer) für die Kollisionsvermeidungsmanöver. (b)

Für einen ersten Vergleich der Gefahrenwahrscheinlichkeit mit den Zeitreserven soll eine gemischte Messreihe von 148 Sequenzen mit insgesamt 33660 Situationen gleichzeitig von beiden Methoden bewertet werden. Es wurden Versuchsfahrten sowohl im Realverkehr, als auch auf einer künstlichen Kreuzung auf einem Testgelände durchgeführt. Im Realverkehr gab es keine Kollisionen und das Ziel war die Zuverlässigkeit der Algorithmen bezüglich der False-Positive-Fehler zu testen. Kritische Situationen und Unfallszenarien zwischen zwei Fahrzeugen wurden auf dem Testgelände in Sinfingern nachgestellt. Damit die Fahrzeuge ein Unfallszenario möglichst unbeschadet überstehen, wurde ein Fahrzeug durch ein ferngesteuertes Softcrash-Target (siehe Abb. 3.9b) ersetzt. Bei dem Softcrash-Target handelt es sich um eine Art Go-Kart mit einer weichen Fahrzeugkarosserie. Somit konnte der Aufprall des Versuchsfahrzeugs auf das Target abgefedert werden. Das Versuchsfahrzeug wurde sowohl von Menschen direkt als auch für knappe Vorbeifahrten ferngesteuert gelenkt. Eine Stereokamera, Fern- und Nahbereich-Radare zum Tracken des entgegenkommenden Fahrzeugs sind im Versuchsfahrzeug verbaut. Im Labor wurden die aufgezeichneten Daten “offline“ ausgewertet.

Zur Bestimmung der Gefahrenwahrscheinlichkeit wurde die Konfiguration aus Tabelle 3.2 verwendet. Der Ansatz mit den Zeitreserven wurde von Andreas Tamke implementiert und parametrisiert. Anders als in der Arbeit [72] wird die Bewegungsprognose für alle Fahrzeuge ausschließlich über eine Extrapolation des aktuell beobachteten Lenkwinkels und konstanter Längsbeschleunigung durchgeführt. Bei den Zeitreserven wurde sowohl die Integration als auch die Kollisionsvermeidungsmanöver über das Einspurmodell mit einer Integrationsschrittweite von 0,05 s berechnet. Zum Bestimmen von TTS wird eine Lenkradwinkelgeschwindigkeit von 500 grad/s für das KVM verwendet. Die maximale Querschleunigung liegt bei 9 m/s^2 . Bei der Berechnung der Reserve TTB wird eine Verzögerung mit -10 m/s^2 betrachtet. Die dritte Zeitreserve TTK wird mit einer Beschleunigung von 3 m/s^2 berechnet. Diese

Beschleunigungswerte entsprechen einem gut motorisierten Fahrzeug.

In Abb. 3.13 sind die Ergebnisse der Gefahrenwahrscheinlichkeit gegen die Zeitreserve Time-To-React aufgetragen. Die Werte des TTR gehen von $-\infty$ bis ∞ . Wenn keine Kollision detektiert wurde, dann ist $TTR = \infty$. Wenn eine Kollision nach dem Modell der Zeitreserven unvermeidbar ist, dann ist $TTR = -\infty$. Es gibt zwar wie zu erwarten

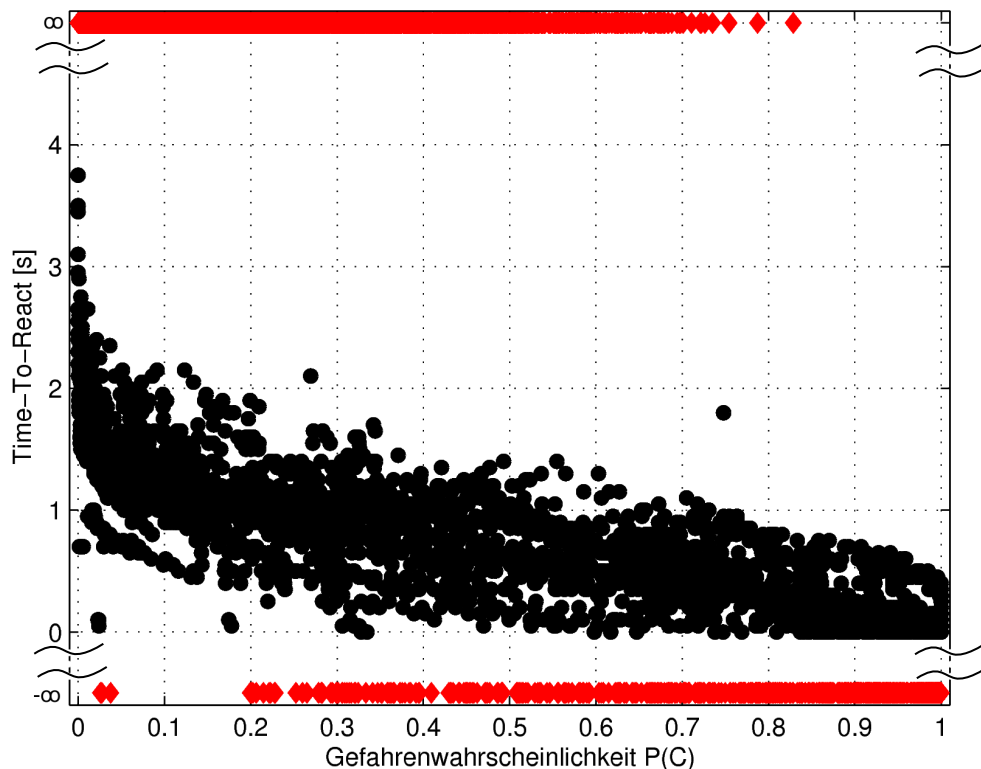


Abbildung 3.13: Verteilung der Gefahrenwahrscheinlichkeit gegen Time-To-React aus 148 Sequenzen mit 33660 ausgewerteten Situationen aus dem Realverkehr und Testgelände. Die beiden Extrema der Zeitreserven (rot) sind $TTR = \infty$ und $TTR = -\infty$.

eine deutliche Korrelation zwischen TTR und Gefahrenwahrscheinlichkeit $P(C)$, aber die Reststreuung von TTR ist von der Größenordnung 1 s, so dass die Frage zu untersuchen ist, was passiert, wenn auf Basis der TTR eine Kollision vorhergesagt wird, die auf Basis von $P(C)$ jedoch unkritisch ist. Gäbe es diese Reststreuung von TTR nicht, wären $P(C)$ und TTR redundante Maße und würden dieselbe Information enthalten.

Die Abb. 3.14 veranschaulicht eine chronologische Sequenz von Kreuzungssituationen zwischen einem Versuchsfahrzeug und einem einbiegenden Entgegenkommer im Realverkehr. Die Bilder stammen aus einer Webcam aus dem Versuchsträger, die

hinter dem Rückspiegel an der Windschutzscheibe angebracht ist. Zwei Algorithmen, das Modell der Gefahrenwahrscheinlichkeit $P(C)$ und die Zeitreservenberechnung Time-To-React TTR, liefen parallel online und bewerteten die Situationen in 0,02 s Zyklen. Die Sequenz visualisiert eine durch die Zeitreserven falsch erkannte kritische Situation, in der der Fahrer des Ego-Fahrzeugs eine Kollision mit KVM nicht mehr verhindern kann. Anders wurde dieselbe Situation durch das Modell der Gefahrenwahrscheinlichkeit als ausweichbar eingeschätzt, und das mit unkritischen Aktionen. In der Situation 3.14a wurde der einbiegende Entgegenkommer zum ersten Mal detektiert. Währenddessen fährt das Versuchsfahrzeug (Ego-Fahrzeug) mit geringer Geschwindigkeit auf ein an der Kreuzung stehendes Fahrzeug zu. Nach 0,2 s in Abb.3.14b überschneiden sich die extrapolierten Spuren des Versuchsfahrzeugs mit der des Einbiegers und eine Kollision wurde detektiert bzw. $TTC < \infty$. Die drei letztmöglichen Kollisionsvermeidungsmanöver (TTS, TTK, TTB) werden bestimmt und die verbleibende maximale Zeitreserve ist $TTR = 0,7$ s. In den zwei nachfolgenden Situationen 3.14c und 3.14d werden normale Situationen über die Zeitreserven als gefährlich bzw. unausweichlich eingestuft, während die Gefahrenwahrscheinlichkeit bis $P(C) = 0,7$ ansteigt. Die Time-To-React besagt, dass der Fahrer des Versuchsfahrzeugs kein Ausweichmanöver mehr durchführen kann, das den Fahrer vor einer Kollision mit dem Entgegenkommer rettet. Die Schwachstelle bei der Berechnung der Zeitreserve liegt in der Bewegungsextrapolation, die in dieser Situation eine Kollision vorhersagt, die aber nicht stattfindet. Somit werden Zeitreserven auf einer falschen Bewegungsprognose berechnet und dies führt zu einem False-Positiv-Fehler. Bei der Berechnung des Handlungsspielraumes wurden mehrere elementare Bewegungshypothesen des Entgegenkommers in Betracht gezogen. Mit den unterschiedlichen Bewegungshypothesen des Versuchsfahrzeugs ergeben sich bei der kombinatorischen Analyse auf Kollision eine Menge von 30% als kollisionsfrei. Mit diesem kollisionsfreien Handlungsspielraum existieren ausreichend mögliche Szenarien, die kollisionsfrei enden können. In den Situationen 3.14e und 3.14f baut sich die Gefahr kontinuierlich ab, während die Berechnung der Zeitreserven keine Kollision gibt.



Abbildung 3.14: Vergleich von Zeitreserven (TTR) mit Gefahrenwahrscheinlichkeit ($P(C)$) für ein einbiegendes Fahrzeug (links). Der Zustand des Fahrzeug des Entgegenkommers wird über eine Fusion der Radar- und SMPC-Daten geschätzt [6].

3.7 Aktionsspezifische Gefahrenwahrscheinlichkeit

Um einen Einblick zu bekommen, welche Aktionen des Fahrers welches Gefahrenpotential aufweisen, lässt sich die Gefahrenwahrscheinlichkeit einer Situation für jeden Fahrer aktionsspezifisch darstellen. Die Gleichung für die Randwahrscheinlichkeit der Gefahr für eine vorgegebene Handlung \mathbf{u}_A ist

$$P(C|\mathbf{u}_A) = \int_{\Phi_B} P(C|\mathbf{u}_A, \mathbf{u}_B) P(\mathbf{u}_B) d\mathbf{u}_B, \quad (3.22)$$

wobei die Integrationsgrenzen $\Phi_B = [a_{x,min}, a_{x,max}] \times [-\dot{\delta}_{max}, \dot{\delta}_{max}]$ aus dem Fahrstil der Fahrer entnommen werden. Die Darstellung der Gefahrenwahrscheinlichkeit in Form einer Karte im Handlungsraum visualisiert das Gefahrenpotential für bestimmte Bereiche des Handelns.

Die Abb. 3.15 visualisiert vier Situationen aus einer realen Sequenz des amerikanischen Abbiegens. Die Bewegungsprognose des jeweiligen Fahrzeugs wird in den Abbildungen als ein "Wedel" von projizierten Spurverläufen mit einem Zeithorizont von 2 s dargestellt. Der dazugehörige Aktionsraum, Lenkwinkelrate $\dot{\delta}$ der Räder über Beschleunigung a_x , wird daneben rechts mit allen gültigen Aktionen, die innerhalb der Handlungsgrenzen liegen, farblich kenntlich gemacht. Jede Farbe kennzeichnet eine bestimmte Gefahrenstufe, die auf einer Skala rechts vom Aktionsraum dargestellt ist. Jede Aktion wird nach ihrer Gefahrenwahrscheinlichkeit einem von vier Intervallen $[0; 0,25)$, $[0,25; 0,5)$, $[0,5; 0,75)$, $[0,75; 1,0]$ zugeteilt. In der Abb. 3.15b liegen Aktionen des Fahrzeugs \mathbf{u}_B mit einer positiven Beschleunigung und einer positiven Lenkwinkelrate im kritischen Bereich. Dieses entspricht einem beschleunigten Abbiegevorgang nach links, das in dieser Situation offensichtlich zu einer Kollision mit Fahrzeug \mathbf{u}_A führt. In Abb. 3.15b kann beobachtet werden, dass beim Fortschreiten der Sequenz nach 0,8 s eine Verzögerung notwendig ist, damit beide Fahrzeuge noch amerikanisch abbiegen können. Die Abb. 3.15c zeigt eine Situation nach 1,32 s, in der für das Fahrzeug \mathcal{A} das Rechtsabbiegen zu einer Kollision führt. Das Abbiegen nach links ist für beide Fahrzeuge relativ unkritisch. Sobald die Fahrzeuge einander passiert haben, wie es die Abb. 3.15d nach 2,4 s darstellt, ist der Aktionsraum beider Fahrzeuge nahezu frei von Kollisionen und die Situation ist unkritisch.

Dazu soll in diesem Abschnitt ein Ansatz vorgestellt werden, dessen Komplexität linear mit der Anzahl der Fahrzeuge ansteigt.

Bisher bezeichnete $P(\mathbf{C})$ die Gefahrenwahrscheinlichkeit zwischen den Fahrzeugen \mathcal{A} und \mathcal{B} . Diese ist für beide Fahrzeuge gleich groß und musste nicht unterschieden werden. Die Notation soll auf mehrere Fahrzeuge unter Berücksichtigung unterschiedlicher Rollen erweitert werden. Es gibt die Rolle des Gefährdeten, z.B. das Systemfahrzeug, und Fahrzeuge von denen eine Gefahr ausgeht. Die Gefahr für das Fahrzeug \mathcal{A} , die von den Fahrzeugen \mathcal{B} und \mathcal{C} ausgeht, wird durch $\mathbf{C}_{\mathcal{A}}^{\mathcal{B},\mathcal{C}}$ bezeichnet. Bisher war diese Notation nicht notwendig, da die Gefahrenwahrscheinlichkeit zwischen nur zwei Fahrzeugen \mathcal{A} und \mathcal{B} kommutativ ist, d.h. $P(\mathbf{C}_{\mathcal{A}}^{\mathcal{B}}) = P(\mathbf{C}_{\mathcal{B}}^{\mathcal{A}})$.

Die bedingte Wahrscheinlichkeit, dass das Fahrzeug \mathcal{A} mit der Fahreraktion $\mathbf{u}_{\mathcal{A}}$ einer Gefahr von den Fahrzeugen \mathcal{B} und \mathcal{C} ausgesetzt ist, soll durch das Maximum der bedingten Gefahrenwahrscheinlichkeiten paarweise je Entgegenkommer abgeleitet werden

$$P(\mathbf{C}_{\mathcal{A}}^{\mathcal{B},\mathcal{C}}|\mathbf{u}_{\mathcal{A}}) = \max(P(\mathbf{C}_{\mathcal{A}}^{\mathcal{B}}|\mathbf{u}_{\mathcal{A}}), P(\mathbf{C}_{\mathcal{A}}^{\mathcal{C}}|\mathbf{u}_{\mathcal{A}})). \quad (3.23)$$

Eine Interaktion der Fahrzeuge \mathcal{B} und \mathcal{C} wird an dieser Stelle aus Kostengründen der Rechenzeit vernachlässigt werden. Die Gesamtwahrscheinlichkeit für Fahrzeug \mathcal{A} von anderen Verkehrsteilnehmern einer Gefahr ausgesetzt zu sein, lässt sich durch eine Randwahrscheinlichkeit darstellen

$$P(\mathbf{C}) = \int_{\Phi_{\mathcal{A}}} P(\mathbf{C}_{\mathcal{A}}^{\mathcal{B},\mathcal{C}}|\mathbf{u}_{\mathcal{A}}) P(\mathbf{u}_{\mathcal{A}}) d\mathbf{u}_{\mathcal{A}}. \quad (3.24)$$

Analog wird die bedingte Gefahrenwahrscheinlichkeit mit Gl. (3.23) auf n -Fahrzeuge ($\mathcal{B}, \mathcal{C}, \mathcal{D}, \dots$) erweitert

$$P(\mathbf{C}_{\mathcal{A}}^{\mathcal{B},\mathcal{C},\mathcal{D},\dots}|\mathbf{u}_{\mathcal{A}}) = \max(P(\mathbf{C}_{\mathcal{A}}^{\mathcal{B}}|\mathbf{u}_{\mathcal{A}}), P(\mathbf{C}_{\mathcal{A}}^{\mathcal{C}}|\mathbf{u}_{\mathcal{A}}), P(\mathbf{C}_{\mathcal{A}}^{\mathcal{D}}|\mathbf{u}_{\mathcal{A}}), \dots). \quad (3.25)$$

Die in (3.24) eingesetzt führt zu einer Gesamtgefahrenwahrscheinlichkeit, der das Fahrzeug \mathcal{A} durch mehrere Fahrzeuge ausgesetzt ist.

Die Abb. 3.16 visualisiert zwei Situationen einer Sequenz mit drei involvierten Fahrzeugen, \mathcal{A} , \mathcal{B} und \mathcal{C} . Eine aktionsspezifische Gefahrenwahrscheinlichkeit $P(\mathbf{C}_{\mathcal{A}}^{\mathcal{B},\mathcal{C}}|\mathbf{u}_{\mathcal{A}})$ zeigt den freien Aktionsraum des Fahrers des Fahrzeugs \mathcal{A} . In Abb. 3.16a gibt es zwei kritische Bereiche V_1 und V_2 im Aktionsraum, die von einem unterschiedlichen Fahrzeug ausgehen. Der Bereich V_1 entsteht durch die prognostizierten Kollisionen mit dem Fahrzeug \mathcal{C} . Der Bereich V_2 durch Kollisionen mit dem Fahrzeug \mathcal{B} . Die Gesamtgefahrenwahrscheinlichkeit nach (3.24) für das Fahrzeugs \mathcal{A} , die von den Fahrzeugen \mathcal{B} und \mathcal{C} ausgeht, ist $P(\mathbf{C}) = 0,61$ und wird links in der Abbildung in einer Liste mit anderen kinematischen Zustandsgrößen, Geschwindigkeit v und Gierrate $\dot{\psi}$,

notiert. Während die Fahrzeuge \mathcal{A} und \mathcal{B} voreinander nach links abbiegen, fährt das dritte Fahrzeug \mathcal{C} geradeaus über die Kreuzung. Das Fahrzeug \mathcal{B} stellt eine Sichtbehinderung dar und führt zu einer kritischen Situation zwischen den Fahrzeugen \mathcal{A} und \mathcal{C} (siehe Abb. 3.16b). Nach 0,72 s ist die Gesamtgefahrenwahrscheinlichkeit auf $P(\mathcal{C}) = 0,99$ gestiegen. Der Aktionsraum ist übersät mit gefährlichen Aktionen.

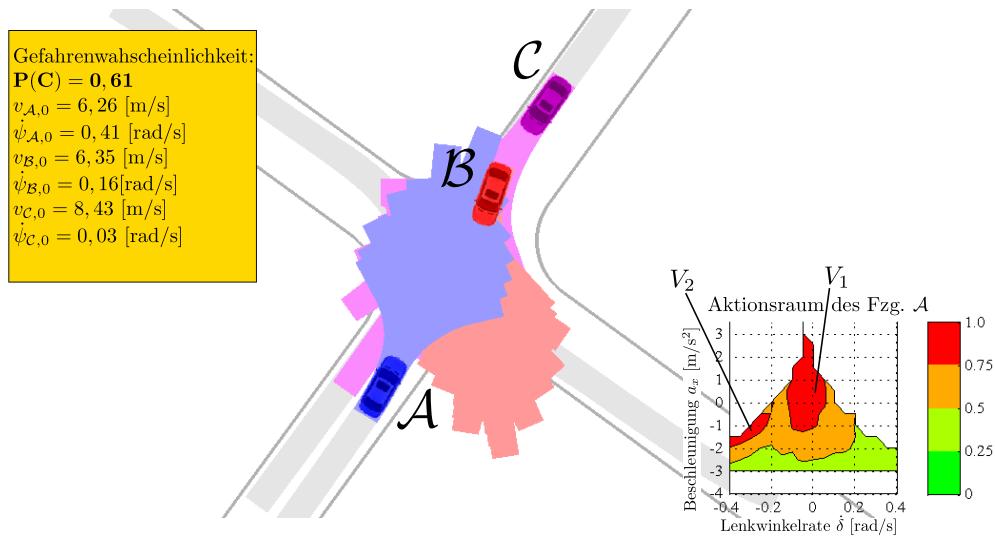
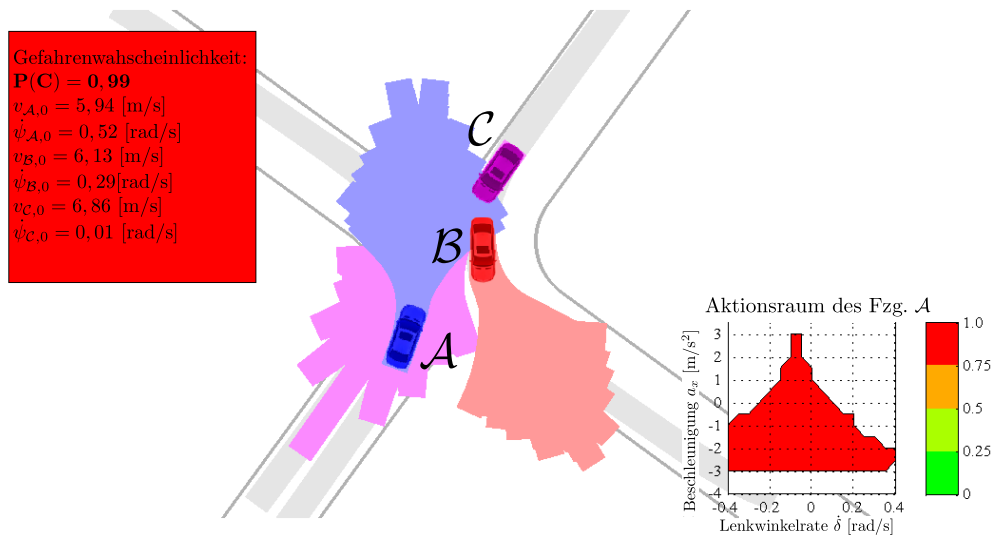
(a) $t = 0$ s(b) $t = 0,72$ s

Abbildung 3.16: Handlungsspezifische Gefahrenwahrscheinlichkeit in zwei Situationen zwischen drei Fahrzeugen.

3.9 Situationserkennung

Beim Aufeinandertreffen mit einem entgegenkommendem Fahrzeug kann der Fahrer eine von zwei Richtungen, links oder rechts vorbei, einschlagen (siehe Abb. 3.17). Dementsprechend werden zwei Situationsklassen definiert, der Fahrer wird nach links (L) oder rechts (R) fahren. Statistisch gesehen, gehen weit über 99 Prozent der Kreuzungssituationen unfallfrei aus. Nutzt man dieses Vorwissen bei der Erkennung der Situationen L und R aus, dann lassen sich Handlungsgrößen, die zur Kollision führen, als unwahrscheinlicher bewerten.

Die bedingte Wahrscheinlichkeitsverteilung, dass eine Aktion \mathbf{u} unkritisch ist, lässt sich komplementär zum Kollisionsereignis C aus (3.22) berechnen

$$P(F|\mathbf{u}) = 1 - P(C|\mathbf{u}). \quad (3.26)$$

Die Verbundwahrscheinlichkeit mit der A-priori-Wahrscheinlichkeit für die Aktion \mathbf{u} ist

$$P(F, \mathbf{u}) = P(F|\mathbf{u}) P(\mathbf{u}) = (1 - P(C|\mathbf{u})) P(\mathbf{u}). \quad (3.27)$$

Auf Basis einer Annahme, dass die Fahrzeuge nicht kollidieren, ist die Randwahrscheinlichkeit für eine Situationsklasse $M = \{L, R\}$

$$P(M) = \int_{\mathbb{R}^2} P(M|F, \mathbf{u}) P(F, \mathbf{u}) d\mathbf{u}, \quad (3.28)$$

wobei $P(M|F, \mathbf{u})$ ein Modell zur Klassifikation von elementaren Manövern ist. Dieses Modell prüft, ob die Gierwinkeldifferenz zwischen Endzustand zum Zeitpunkt T_H und Startzustand t_0 eines elementaren Manövers positiv oder negativ ist. Ist der




Abbildung 3.17: Zwei mögliche Situationsklassen für das untere Fahrzeug. Der Fahrer wird links oder rechts am oberen Fahrzeug vorbei fahren.

Winkel positiv, dann biegt das Fahrzeug insgesamt nach links ab

$$P(L|F, \mathbf{u}) = \begin{cases} 1 & (\psi(T_H) - \psi(0)) \geq 0 \\ 0 & \text{sonst} \end{cases} \quad (3.29)$$

Bei negativer Gierwinkeldifferenz biegt das Fahrzeug nach rechts ab. Die bedingte Wahrscheinlichkeit für die Situationsklasse R ist dann 1,

$$P(R|F, \mathbf{u}) = \begin{cases} 1 & (\psi(T_H) - \psi(0)) \leq 0 \\ 0 & \text{sonst} \end{cases} \quad (3.30)$$

3.10 Zusammenfassung

Eine elementare Aktion in Form von Bremsen, Lenken oder beides reicht aus, um nachzuweisen, dass in einer Situation zwischen zwei Fahrzeugen ein Fahrer am anderen vorbei fahren kann. Nach diesem Grundgedanken soll eine Bewegungsprognose konzipiert werden. Es werden ausschließlich Aktionen betrachtet, die nach unserer Definition unkritisch sind bzw. innerhalb des typischen Fahrbereichs liegen. Der Vorteil dabei ist, dass extreme Ausweichmanöver gezielt aus dem Hypothesenraum ausgeschlossen werden. Diese Manöver wären bereits ein Indiz für eine kritische Situation. Damit hebt sich das Verfahren von vielen anderen Ansätzen der Gefahrenbewertung ab, die für einen Fahrer auch extreme Manöver als Option zulassen. Die Berücksichtigung einer Prognoseunsicherheit für jeden Fahrer macht diesen Ansatz weniger anfällig gegen False-Positive-Fehler.

Die Gefahr in einer Kreuzungssituation hängt von der Größe des kollisionsfreien Aktionsraumes beider Fahrer ab. Die Existenz eines Mindestraumes als ein Indiz für die Feel-Safe Zone wurde empirisch ermittelt. In dieser Zone hätten beide Fahrer bei aufmerksamer Fahrweise genügend Handlungsmöglichkeiten, um mit ihrer unkritischen Fahrweise aneinander vorbei zu fahren. Diese Gefahrenbewertung wurde durch ein stochastisches Modell untermauert. Ein Vorteil des hier vorgestellten Ansatzes zur Berechnung der Gefahrenwahrscheinlichkeit im Vergleich zu Zeitreserven konnte an einem False-Positiv-Fehler aufgezeigt werden.

Die Berechnung der Gefahrenwahrscheinlichkeit konnte durch eine paarweise Betrachtung auf mehrere Fahrzeuge erweitert werden. Eine aktionsspezifische Gefahrenwahrscheinlichkeit visualisiert das Gefahrenpotential im Aktionsraum. Unter Ausnutzung des Handlungsspielraumes zweier Fahrer werden Situationen erkannt, die auf das Verhalten des Fahrers hinweisen. Eine echtzeitfähige Implementierung mit einer Worst-Case-Execution-Time von 0,02 s bei zwei Fahrzeugen auf einem Versuchsfahrzeug ermöglichte einen erfolgreichen Einsatz im Realverkehr. Eine Erweiterung des Ansatzes wurde in einer Simulation für 3 Fahrzeugen untersucht. Die Erweiterung auf 3 Fahrzeuge erfolgt durch eine paarweise Schätzung der Gefahrenwahrscheinlichkeit und ist ausschließlich bezogen auf das Ego-Fahrzeug. Bei einer vollständigen

Betrachtung aller Aktionskombinationen würde die Rechenzeit mit Anzahl der Fahrzeuge exponentiell wachsen. Diese paarweise Betrachtung ist ein Trade-off zwischen Rechenzeit und Vollständigkeit.

Spurwechselmanöver und andere komplexe Manöver als potentielle Fahrerhandlungen werden in diesem Ansatz nicht betrachtet. Erweitert man die Zielstellung um Aktionen innerhalb eines befahrbaren Raumes, d.h. inklusive stationärer Hindernisse, dann werden komplexere Manöver benötigt. Eine Erweiterung der elementaren Aktion auf eine Folge von Aktionen, wie in [14] [22], könnte das Aktionsrepertoire eines Fahrers auf z.B. Spurwechselmanöver erweitern. Damit könnten Vorbeifahrten an mehreren Hindernissen berücksichtigt werden. Für diesen erweiterten Ansatz im Realverkehr, muss dafür eine zuverlässige Erkennung der Umwelt mit sämtlichen Hindernissen gegeben sein. Dieses ist bereits eine Herausforderung.

Interaktionsmodell

4.1 Zielstellung

Eine Erkennung der Fahrerabsichten mit der Annahme, dass die Fahrer bei über 99% der Situationen nicht kollidieren, und deshalb den kollisionsfreien Freiraum nutzen, wurde zuvor im Abschnitt 3.9 präsentiert. Dementsprechend basiert diese Situationsklassifikation auf dem kollisionsfreien Handlungsspielraum.

In diesem Kapitel bleibt das Ziel die Erkennung von Fahrerabsichten, jedoch wird ein neues Paradigma der Bewegungsprognose in Betracht gezogen. Diese wurde in der Arbeit von Hermes et al. [36] vorgestellt. Statt der elementaren Aktionen aus Abschnitt 3.2, die mittels Einspurmodell generiert wurden, liefert eine Datenbank die Trajektorien für die Prognose. Diese Datenbank besteht aus einer Menge von Trajektorien, die zuvor während Abbiegevorgängen an unterschiedlichen Kreuzungen aufgezeichnet wurden. Sie fungiert als eine Art Erfahrungsspeicher. Die Anwendung eines derartigen Erfahrungsspeichers bei der Situationsklassifikation erfolgt über einen Abgleich des beobachteten Bewegungsverlaufes mit den gegebenen Trajektorien aus dem Speicher. Das Ziel dabei ist eine Suche nach ähnlichsten Trajektorien. Die Fortsetzungsstücke der ähnlichsten Trajektorien fungieren als Prognose, dessen Eintrittswahrscheinlichkeit aus dem Ähnlichkeitsgrad abgeleitet wird. Der Ansatz von Hermes et al. [36] wird auf jedes Fahrzeug einzeln angewendet und entspricht damit einer Einzeltrajektorienprognose. Bei einer Anwendung der Einzeltrajektorienprognose auf eine Situation zwischen zwei Fahrzeugen ergibt sich eine statistisch unabhängige Bewegungsprognose. Unter der Annahme, dass beide Fahrer nicht interagieren, mag dieses voneinander unabhängige Verhalten zutreffen. Um auch eine Interaktion beider Fahrer zu berücksichtigen, soll in diesem Kapitel eine Betrachtung von Trajektorienpaaren die Prognose verbessern.

Ein Interaktionsmodell soll die fehlende Korrelation zwischen zwei unabhängigen Einzeltrajektorienprognosen herstellen. Dieses Modell nutzt die Kritikalität einer Situation, um die Eintrittswahrscheinlichkeit eines Trajektorienpaares zu gewich-

ten. Dazu werden alle möglichen Paare von Bewegungshypothesen zwischen zwei Fahrzeugen auf die Kritikalität bewertet. Einerseits sind die kritischen Hypothesen im Straßenverkehr statistisch eher unwahrscheinlich. Andererseits kann aber auch angenommen werden, dass die Fahrer eine Kollision nicht beabsichtigen bzw. diese vermeiden wollen. Diese beiden Aspekte sollen in einem Interaktionsmodell [40], [41], [42] berücksichtigt werden. Mit diesem Modell soll in unkritischen Situationen die Wahrscheinlichkeit der kollisionsfreien Bewegungshypothesen erhöht werden. Solange es nicht genug Indizien über eine bevorstehende gefährliche Situation gibt, sind die kollisionsfreien Hypothesenpaare wahrscheinlicher als die mit Kollision.

Eine Annahme, dass der Hauptfokuspunkt eines Fahrers in Fahrtrichtung liegt, ermöglicht es die gegenseitige Sichtbarkeit der Fahrzeuge auf Basis der Hypothesenpaare zu berechnen und bei der Schätzung der Gefahr zu berücksichtigen. Je schlechter die Sichtbarkeit bei einem prognostizierten Manöverpaar, desto früher wird eine fehlende Interaktion detektiert.

In der Abb. 4.1 werden die einzelnen Verarbeitungsschritte des Ansatzes zur Klassifikation einer Situation zwischen zwei Fahrzeugen veranschaulicht. Im Abschnitt 4.2 wird die Einzeltrajektorienprognose von Hermes et al. [36], die eine stochastischen Suche auf einer Bewegungsdatenbank von Einzeltrajektorien beschreibt, umrissen. Eine




Abbildung 4.1: Unabhängige Bewegungsprognose für zwei Fahrzeuge wird in Trajektorienpaare zerlegt und auf Interaktion analysiert. Anschließend erfolgt eine Klassifikation der vorliegenden Situation auf Basis der Trajektorienpaarprognose.

Erweiterung dieser Prognose auf zwei Fahrzeuge und sich damit ergebende Paare von Trajektorien erfolgt im Abschnitt 4.3. Die Basis dafür liefert ein Interaktionsmodell im Abschnitt 4.4.2, das Trajektorienpaare auf Kritikalität mit gegenseitiger Sichtbarkeit analysiert und gewichtet. Auf Basis der Trajektorienpaarprognose erfolgt im Abschnitt 4.4 eine Situationsklassifikation. Die Klassifikation von Trajektorienpaaren erfolgt mittels Polynomklassifikator in Abschnitt 4.4.1 mit einer Konfidenzabbildung in Abschnitt 4.4.2. Eine Evaluation der Situationsklassifikation auf 81 Sequenzen aus dem Realverkehr erfolgt im Abschnitt 4.5. Für die Situationsklasse "Kollision" wird in Abschnitt 4.4.3 die Kollisionswahrscheinlichkeit eingeführt. Im Kontext der gegenseitigen Sichtbarkeit zweier Fahrer wird diese Kollisionswahrscheinlichkeit im Abschnitt 4.5.1 näher betrachtet.

4.2 Einzeltrajektorienprognose

4.2.1 Bewegungsrepräsentation und Bewegungsdatenbank

Das Bewegungsmuster eines Fahrzeugs wird in Form einer diskreten Trajektorie formalisiert. Eine chronologische Folge von Tupeln aus kinematischen Zuständen \mathbf{x} mit dazugehörigem Zeitstempel t beschreibt ein Bewegungsmuster in Form einer Trajektorie $X = \{(\mathbf{x}, t)\}$. Der Zustand \mathbf{x} beinhaltet eine Menge von kinematischen Größen wie Position (x, y) , Gierwinkel ψ , Geschwindigkeit v , Gierrate $\dot{\psi}$. Anders als im Kapitel 3.2 werden hier die Trajektorien nicht mittels eines Einspurmodells vorhergesagt, sondern ergeben sich aus einer Messung im Realverkehr.

4.2.2 Vergleich der Bewegungsmuster

Zum Vergleichen der Form von Trajektorien verwenden Hermes et al. [36] ein Matching-Verfahren, das ursprünglich seinen Einsatz beim Vergleichen von Zeichenketten fand. Die *Longest-Common-Subsequence-Metric* (LCS) [75] wurde als eine adäquate Trajektorienmetrik erachtet. Zum Vergleichen von Bewegungspfaden, die auf unterschiedlichen Kreuzungen aufgezeichnet wurden, erweitern Hermes et al. [36] die LCS um die Eigenschaft der Rotations- und Translationsinvarianz. Das Beispiel in Abb. 4.2 veranschaulicht zwei unterschiedlich lange Trajektorien A und B. Das Ziel ist es die beiden Trajektorien unabhängig von ihrer Lage im Weltkoordinatensystem zu vergleichen. Die Punktepaare der ähnlichsten Trajektorienabschnitte wurden zur Veranschaulichung über rote Linien verbunden. Die Trajektorie B ist bezüglich ihrer Form einem Abschnitt der Trajektorie A gleich. Die Metrik dazu ist die *Quaternion-based Rotationally Invariant LCS* (QRLCS), die im Abschnitt 4.2.4 genauer betrachtet wird.




Abbildung 4.2: Ein rotations- und translationsinvarianter Vergleich zweier unterschiedlich langer Pfad-Trajektorien.

Zum Vergleichen der Form von Trajektorien verwenden Hermes et al. [36] die LCS um die Eigenschaft der Rotations- und Translationsinvarianz. Das Beispiel in Abb. 4.2 veranschaulicht zwei unterschiedlich lange Trajektorien A und B. Das Ziel ist es die beiden Trajektorien unabhängig von ihrer Lage im Weltkoordinatensystem zu vergleichen. Die Punktepaare der ähnlichsten Trajektorienabschnitte wurden zur Veranschaulichung über rote Linien verbunden. Die Trajektorie B ist bezüglich ihrer Form einem Abschnitt der Trajektorie A gleich. Die Metrik dazu ist die *Quaternion-based Rotationally Invariant LCS* (QRLCS), die im Abschnitt 4.2.4 genauer betrachtet wird.

4.2.3 Longest Common Subsequence (LCS)

Beim String-Matching geht es darum zwei Zeichenketten miteinander zu vergleichen und die Anzahl der übereinstimmenden Zeichen zu berechnen. Ein Ansatz zum Vergleichen von Zeichenketten bietet die LCS-Metrik [54], [9]. Hier sollen die Zeichenketten durch Trajektorien ersetzt werden. Ihre Anwendung auf zwei Trajektorien $(\mathbf{a}_i, t_i) \in A$ und $(\mathbf{b}_j, t_j) \in B$ erfordert eine Definition eines Ähnlichkeitsmaßes zwischen zwei beliebigen Punkten \mathbf{a}_i und $\mathbf{b}_j \in \mathbb{R}^D$ der Trajektorien. Im Kontext der LCS-Metrik wird die Ähnlichkeit zwischen zwei Zeichen durch eine Distanz $\text{dist}(\mathbf{a}_i, \mathbf{b}_j)$ zwischen zwei Punkten ersetzt. Die Längen der Trajektorien N_A und N_B dürfen

unterschiedlich sein. Hinzu wird eine feste Entscheidungsumgebung ϵ mit Grenzen bezüglich jeder Punktdimension $d = 1, \dots, D$, z.B. die x -Position eines Fahrzeugs, definiert. Über eine lineare Abbildung im Intervall $[0, \epsilon^{(d)}]$ soll die Distanz zwischen den Punkten \mathbf{a}_i und \mathbf{b}_j berechnet werden, wobei L^1 -Metrik (Manhattan-Distanz) benutzt wird

$$\text{dist}(\mathbf{a}_i, \mathbf{b}_j) = \begin{cases} 0 & \text{wenn } \exists d \in D: L^1(a_i^{(d)}, b_j^{(d)}) > \epsilon^{(d)} \\ \frac{1}{D} \sum_{d=1}^D \left(1 - \frac{L^1(a_i^{(d)}, b_j^{(d)})}{\epsilon^{(d)}} \right) & \text{sonst.} \end{cases} \quad (4.1)$$

Eine Trajektorie A der Länge N_A ohne das letzte Element $(\mathbf{a}_{N_A}, t_{N_A})$ ist definiert durch $\text{head}(A) := [(\mathbf{a}_1, t_1), \dots, (\mathbf{a}_{N_A-1}, t_{N_A-1})]$. Die LCS-Metrik ist über eine rekursive Gleichung mit der Distanzfunktion (4.1) gegeben

$$\text{LCS}(A, B) = \begin{cases} 0 & \text{wenn } N_A = 0 \wedge N_B = 0 \\ \text{LCS}(\text{head}(A), \text{head}(B)) + \text{dist}(\mathbf{a}_{N_A}, \mathbf{b}_{N_B}) & \text{wenn } \text{dist}(\mathbf{a}_{N_A}, \mathbf{b}_{N_B}) \neq 0 \\ \max\{\text{LCS}(\text{head}(A), B), \text{LCS}(A, \text{head}(B))\} & \text{sonst.} \end{cases} \quad (4.2)$$

Die LCS-Distanz zwischen einer Trajektorie A und einer Trajektorie B lässt sich über die Gleichung

$$\text{dist}_{\text{LCS}}(A, B) = 1 - \frac{\text{LCS}(A, B)}{\min\{N_A, N_B\}}, \quad (4.3)$$

mit $\text{dist}_{\text{LCS}}(A, B) \in [0, 1]$ berechnen.

4.2.4 Quaternion-based Rotationally Invariant LCS (QRLCS)

Die LCS lässt sich mit Hilfe von dynamischer Programmierung (DP) [8] berechnen. Die Teilergebnisse des Vergleichs zweier Pfad-Trajektorien (i.e. xy -Positionen über der Zeit) werden in einer DP-Tabelle abgespeichert. Diese Teilergebnisse beziehen sich auf (Sub-)Trajektorien. Jede LCS-Distanz in der DP-Tabelle ist optimal für die betrachteten (Sub-)Trajektorien. Eine optimale Rotation und Translation für (Sub-)Trajektorien erhält man bei der Betrachtung dieser als zwei Punktmengen, deren Punkt-zu-Punkt-Zuweisungen in der DP-Tabelle abgespeichert sind. Auf Basis dieser DP-Tabelle werden ein Rotationswinkel und zwei Mittelpunkte für jede Punktmenge inkrementell berechnet.

Die optimale Translation einer Pfad-Trajektorie A auf eine Pfad-Trajektorie B lässt sich durch ihre Mittelwerte $\boldsymbol{\mu}_a$ und $\boldsymbol{\mu}_b$ in der xy -Ebene bestimmen. Eine rekursive

Mittelwert-Berechnung für eine Anzahl \tilde{N} der Punkte:

$$\boldsymbol{\mu}_{\mathbf{a},\tilde{N}} = \frac{1}{\tilde{N}} \sum_{t=1}^{\tilde{N}} \mathbf{a}_t = \frac{\tilde{N}-1}{\tilde{N}} \boldsymbol{\mu}_{\mathbf{a},\tilde{N}-1} + \frac{1}{\tilde{N}} \mathbf{a}_{\tilde{N}}. \quad (4.4)$$

Für eine optimale Rotation, liefert Horn [38] eine geschlossene Lösung des Minimierungsproblems für kleinste Quadrate einer absoluten Orientierung mit Quaternionen. Ein Quaternion ist eine komplexe Zahl mit drei imaginären Anteilen oder ein Skalar mit einem dreidimensionalen kartesischen Vektor $\hat{\mathbf{q}} = q_0 + iq_x + jq_y + kq_z \equiv [q_0, \mathbf{q}]$. Ein Punkt $\hat{\mathbf{a}} \in \mathbb{R}^3$ lässt sich über einen Einheitsquaternion $\hat{\mathbf{q}}$ im dreidimensionalen Raum drehen

$$[0, \hat{\mathbf{a}}^R] = \hat{\mathbf{q}}[0, \hat{\mathbf{a}}] \hat{\mathbf{q}}^{-1}, \quad (4.5)$$

Ein Quaternion für die Rotation kann unter der Bedingung, dass der Rotationswinkel θ_{Rot} und der dreidimensionale Rotationsvektor $\mathbf{n}_{Rot} = (n_x, n_y, n_z)$ bekannt sind, erzeugt werden

$$\hat{\mathbf{q}} = \sqrt{\frac{1 + \cos \theta_{Rot}}{2}} + \frac{\sin \theta_{Rot}}{\sqrt{2(1 + \cos \theta_{Rot})}} (i n_x + j n_y + k n_z). \quad (4.6)$$

Aufgrund der Annahme einer ebenen Welt wird der Rotationsvektor auf den festen Wert $\mathbf{n}_{Rot} = [0, 0, 1]$ gesetzt. Dieser beschreibt die z -Achse, um die gedreht werden soll. Für die Rotation auf einer Ebene schlägt Horn [38] eine Methode zur Zusammensetzung des Rotationsvektors für zwei Pfadmengen der Länge \tilde{N} aus impliziten trigonometrischen Werten vor

$$\sin \theta_{Rot} = \frac{S_{\tilde{N}}}{\sqrt{S_{\tilde{N}}^2 + C_{\tilde{N}}^2}}, \quad \cos \theta_{Rot} = \frac{C_{\tilde{N}}}{\sqrt{S_{\tilde{N}}^2 + C_{\tilde{N}}^2}}. \quad (4.7)$$

Bei einer Rotation der Pfade um ihre Mittelwerte $\boldsymbol{\mu}_{\mathbf{a},\tilde{N}}$ und $\boldsymbol{\mu}_{\mathbf{b},\tilde{N}}$ ergeben sich die Hilfsvariablen aus der Gleichung (4.7) zu

$$S_{\tilde{N}} = \left(\sum_{t=1}^{\tilde{N}} (\mathbf{a}_t \times \mathbf{b}_t) - \tilde{N} (\boldsymbol{\mu}_{\mathbf{a},\tilde{N}} \times \boldsymbol{\mu}_{\mathbf{b},\tilde{N}}) \right)^T \mathbf{n}_{Rot} \quad (4.8)$$

$$C_{\tilde{N}} = \sum_{t=1}^{\tilde{N}} \mathbf{a}_t^T \mathbf{b}_t - \tilde{N} \boldsymbol{\mu}_{\mathbf{a},\tilde{N}}^T \boldsymbol{\mu}_{\mathbf{b},\tilde{N}}, \quad (4.9)$$

wobei \times das Kreuzprodukt bezeichnet. Als Ergebnis wird ausschließlich der inkrementelle Anteil $\boldsymbol{\mu}_{\mathbf{a},\tilde{N}}$ und $\boldsymbol{\mu}_{\mathbf{b},\tilde{N}}$ (Gl. (4.4)), $\sum_{t=1}^{\tilde{N}} (\mathbf{a}_t \times \mathbf{b}_t)$ (aus Gl. (4.8)) und $\sum_{t=1}^{\tilde{N}} \mathbf{a}_t^T \mathbf{b}_t$ (4.9) für jeden Test einer Zuweisung in der DP-Tabelle zur Garantie der besten Rotation und Translation gespeichert.

4.2.5 Stochastische Suche in einer Bewegungsdatenbank

Ein beobachtetes Fahrerverhalten, das z.B. über einen bestimmten Zeithorizont getrackt wurde, beschreibt eine Bewegungshistorie H_t . Anders als im Kapitel 3 soll hier anstatt eines einzelnen beobachteten Zustandes \mathbf{x}_0 eine gesamte beobachtete Trajektorie H_t von Zuständen betrachtet werden. Diese liefert die Basis zur Suche nach ähnlichen Bewegungsmustern bzw. Trajektorien X_t in einer Bewegungsdatenbank. Eine sequentielle Suche wäre eine Lösung, bei der jede Trajektorie aus der Bewegungsdatenbank mit der Historie verglichen wird. Dieses hätte bei großen Datenbanken den Nachteil einer ineffizienten Suche, weil jede Trajektorie zum Vergleich betrachtet werden müsste. Eine elegantere Lösung ist gemäß [36] eine stochastische Suche von Sidenbladh et al. [68], die rekursiv auf den ähnlichsten Trajektorien aus dem vorherigen Zeitschritt aufbaut.

Bedingt durch eine Historie H_t wird eine A-posteriori-Verteilung $p(X_t|H_t)$ der Trajektorien X_t aus der Bewegungsdatenbank geschätzt. Einen Ansatz zur rekursiven Schätzung dieser Verteilung über die Zeit t bietet der Condensation Algorithmus von Black et al. [11]

$$p(X_t|H_t) = \eta p(H_t|X_t) \int p(X_t|X_{t-1}) p(X_{t-1}|H_{t-1}) dX_{t-1}, \quad (4.10)$$

mit Normalisierungskonstante η , Likelihood $p(H_t|X_t)$, bedingter Zustandsübergangswahrscheinlichkeit $p(X_t|X_{t-1})$ und der A-posteriori-Verteilung vom vorherigem Zeitschritt $p(X_{t-1}|H_{t-1})$. Diese Verteilung wird durch eine endliche Menge von Trajektorien $\{X_t^{(s)}\}_S$ (siehe Abb. 4.3) mit Hilfe des Particle-Filters über die Zeit propagiert. Jedes Particle $X_t^{(s)}$ ist eine Datenbanktrajektorie und $p(X_t|H_t)$ ist das dazugehörige Gewicht. Die Zustandsübergangswahrscheinlichkeit $p(X_t|X_{t-1})$ beschreiben Sidenbladh et al. [68] ausführlich. Dabei wird im Merkmalsraum ein Binärbaum erzeugt, mit dem ein Übergangsschritt von $t-1$ nach t über eine probabilistische Suche nach Trajektorien erfolgt. Zuvor werden alle Trajektorien der Bewegungsdatenbank in Tschebyschow-Polynomen zerlegt und die Tschebyschow-Koeffizienten fungieren als Merkmale.

Die Wahrscheinlichkeit $p(H_t|X_t)$ wird aus Ähnlichkeit der beobachteten Historie H_t mit einer Trajektorie aus der Bewegungsdatenbank X_t abgeleitet. Die Ähnlichkeit wird über ein Distanzmaß [40] zwischen Trajektorien ermittelt. Das Distanzmaß setzt sich zusammen aus der QRLCS-Metrik, der Differenz der Gierrate und der Differenz der Geschwindigkeit.

In der Regel fahren die Fahrer nicht auf den Gehwegen, sondern bleiben auf der Straße. Mit dieser Annahme ist es naheliegend, die prognostizierten Trajektorien, welche dieser Annahme widersprechen, geringer zu gewichten und erhalten daher eine geringe A-posteriori-Wahrscheinlichkeit. Hierfür wird allerdings eine digitale




Abbildung 4.3: Ein Menge von Trajektorienabschnitten $X_t^{(s)}$, die nach der QRLCS-Metrik ähnlich zu der beobachteten Historie H_t sind. Die Fortsetzungen ab dem (fetten) Punkt auf der Stoßstange fungieren als Bewegungsprognose.

Karte von der Kreuzung in Betracht gezogen.

4.3 Trajektorienpaarprognose

Das Resultat des Particle-Filters aus Abschnitt 4.2.5 in einer Situation mit zwei Fahrzeugen \mathcal{A} und \mathcal{B} ergibt zwei Mengen von Trajektorienhypothesen $X_{\mathcal{A}}^{(1)}, \dots, X_{\mathcal{A}}^{(N)}$ und $X_{\mathcal{B}}^{(1)}, \dots, X_{\mathcal{B}}^{(M)}$ mit dazugehörigen Wahrscheinlichkeiten $P_{\mathcal{A}}^{(1)}, \dots, P_{\mathcal{A}}^{(N)}$ und $P_{\mathcal{B}}^{(1)}, \dots, P_{\mathcal{B}}^{(M)}$. Jede dieser Trajektorien setzt sich aus einem "History-Teil" und einem "Prognose-Teil" [40] zusammen (siehe Abb. 4.3). Der Prognosehorizont der Trajektorie beträgt 2,5 s. Die Trajektorienhypothesen lassen sich zu Paaren $X^{(nm)} = (X_{\mathcal{A}}^{(n)}, X_{\mathcal{B}}^{(m)})$ kombinieren. Jedes Paar repräsentiert ein mögliches Szenario. Die dazugehörige unkorrelierte Verbundwahrscheinlichkeit beträgt $P^{(nm)} = P_{\mathcal{A}}^{(n)} P_{\mathcal{B}}^{(m)}$.

Ein Beispiel für eine Bewegungsprognose nach Hermes et al. [36] zweier auf eine Kreuzung zufahrender Fahrzeuge veranschaulicht die Abb. 4.4a. Die Trajektorienhypothesen werden als durchgezogene Pfade mit der dazugehörigen Eintrittswahrscheinlichkeit nach (4.10) dargestellt. Die gestrichelte Linie repräsentiert den Ground-Truth-Pfad. In diesem Fall biegt das untere Fahrzeug nach rechts ab und das obere fährt geradeaus durch. Für das obere Fahrzeug wurde eine Geradeausfahrt mit einer hohen Wahrscheinlichkeit erkannt. Bei dem unteren Fahrzeug streuen die Bewegungshypothesen in mehrere Richtungen. Die Abb. 4.4b hebt für ein Hypothesenpaar eine zukünftige Kollision hervor. Die dazugehörige Verbundwahrscheinlichkeit ist 0,49. Da es sich hierbei um eine unabhängige Bewegungsprognose handelt, stellt sich die Frage, ob dieses Ereignis wirklich mit dieser Wahrscheinlichkeit eintreten wird.

Die Korrelation zwischen einem Hypothesenpaar wird über ein Interaktionsmodell im folgenden Abschnitt vorgestellt.

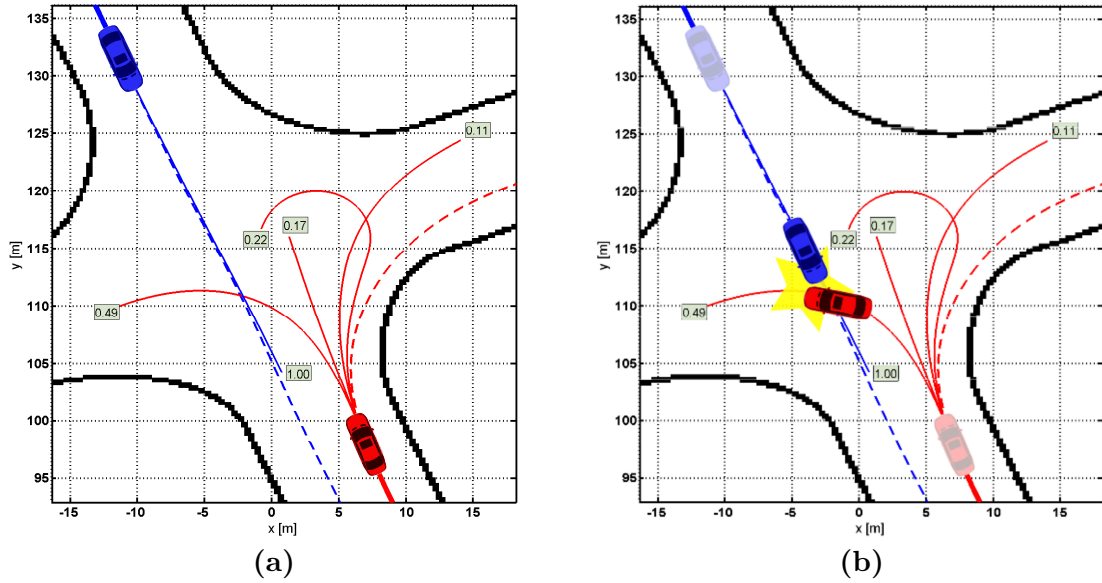


Abbildung 4.4: (a) Bewegungshypothesen (durchgezogene Pfade) mit Eintrittswahrscheinlichkeiten (in Kästchen) nach (4.10) für zwei auf eine Kreuzung zufahrende Fahrzeuge, wobei die gestrichelten Linie die Ground-Truth-Pfade darstellen. (b) Eine prognostizierte Kollision mit einer unkorrelierten Verbundwahrscheinlichkeit von 0,49.

4.3.1 Interaktionsmodell

Die beiden Annahmen, dass Fahrer (i) generell dazu neigen Kollisionen zu vermeiden und (ii) die Verschlechterung der Sichtbarkeit eines anderen Verkehrsteilnehmers die Wahrscheinlichkeit einer Interaktion vermindert, sollen in einem Interaktionsmodell zusammengefasst werden. Das Ziel des Interaktionsmodells ist es die Wahrscheinlichkeit von Kollisionshypothesen, deren Zeitreserve Time-To-Collision $t_c^{(nm)}$ größer als eine Interaktionszeit $t_r^{(nm)}$ ist und beide Fahrer im gegenseitigen Sichtfeld liegen, geringer zu gewichten. Dazu wird die Gewichtsfunktion $\rho^{(nm)}$ eingeführt

$$\rho^{(nm)} = (1 - \rho_{\min}) e^{-\frac{1}{2} \left(\frac{t_c^{(nm)}}{t_r^{(nm)}} \right)^2} + \rho_{\min} \quad (4.11)$$

mit einer unteren Grenze ρ_{\min} . Die Zeit bis zur Kollision $t_c^{(nm)}$ wird mittels Kollisionsüberprüfung für das Trajektorienpaar (nm) bestimmt. Wenn keine Kollision vorliegt ist das Gewicht $\rho^{(nm)} = 1$ und die unkorrelierte Verbundwahrscheinlichkeit $P^{(nm)}$ bleibt unverändert. Die Sichtbarkeit der Verkehrsteilnehmer untereinander wurde in [22] als ein Einflussfaktor zur Gefahrenbewertung eingeführt. In unserem Modell wird der Hauptfokus des Fahrers in die prognostizierte Fahrtrichtung, also auf eine Bewegungshypothese, gelegt. Der Hauptfokus eines Fahrers, repräsentiert durch den Vektor \mathbf{p}_f , zeigt von der aktuellen Position des Fahrers auf die prognostizierte Position einer Bewegungshypothese in 2 s.

In der Abb. 4.5 werden die Winkel $\alpha^{(nm)}$ und $\beta^{(nm)}$ der Sichtbarkeit für ein Hypothesenpaar $X^{(nm)}$ veranschaulicht. Der Sichtbarkeits-Winkel ist aufgespannt zwischen dem Fokusvektor \mathbf{p}_{fA} und der aktuellen Position der Fahrzeugs \mathcal{B} . Analog wird umgekehrt der Sichtbarkeitswinkel für eine Hypothese des Fahrzeugs \mathcal{B} berechnet. Die Interaktionszeitskala ist näherungsweise proportional abhängig von dem Mittelwert der Sichtbarkeitswinkel

$$t_r^{(nm)} = \frac{1}{2b} (\alpha^{(nm)} + \beta^{(nm)}) \quad (4.12)$$

mit einer empirisch gewählten Konstante $b = 0,6$ [rad/s] angenommen.




Abbildung 4.5: Im der Abb. (a) ist der Sichtbarkeitswinkel α für das Fahrzeug \mathcal{A} auf Basis der Bewegungshypothese (durchgezogene Linie) und analog in (b) der Sichtbarkeitswinkel β für das Fahrzeug \mathcal{B} dargestellt.

4.4 Situationsklassifikation

Die Absicht eines Fahrzeugs, welches sich einer Kreuzung nähert, ist mit hoher Wahrscheinlichkeit die Kreuzung zu passieren. Bei einer vierarmigen Kreuzung mit zwei senkrecht zueinander verlaufenden Straßen gibt es mehrere Möglichkeiten die Kreuzung zu überqueren. Der Fahrer kann geradeaus (G) über die Kreuzung fahren, nach links (L) oder nach rechts (R) in die Querstraße abbiegen. Das Wenden an Kreuzungen wird hier außer Acht gelassen. Bei zwei zeitnah auf die Kreuzung zufahrenden Fahrzeugen \mathcal{A} und \mathcal{B} ergeben sich kombinatorisch folgende Situationsklassen $\Omega = \{LL, LG, LR, RL, RG, RR, GL, GG, GR\}$. Zum Beispiel bedeutet die Klasse LR, dass das Fahrzeug \mathcal{A} nach links und das Fahrzeug \mathcal{B} nach rechts abbiegt. Die Situationsklassifikation verwendet als Input die Trajektorienhypothesen aus der Bewegungsprognose nach Hermes et al. [36], die in den vorherigen Abschnitten beschrieben wurde.

Zur Kompression werden die Trajektorienpaare $X^{(nm)} = (X_A^{(n)}, X_B^{(m)})$ in Tschebyschow-Polynome [61] zerlegt. Jede Dimension der Zustandstrajektorien wie x -Position, y -Position, Gierwinkel, Gierrate wird einzeln zerlegt. Eine ausführliche Beschreibung der Zerlegung wird im Kapitel 5.2.1 diskutiert. Die Tschebyschow-Koeffizienten der Polynome werden zu einem Merkmalsvektor $\bar{y}^{(nm)}$ aneinander gereiht.

Im ersten Schritt wird die Anfahrtsrichtung beider Fahrzeuge auf Basis des relativen Gierwinkels erkannt. Bei einem hierarchischen Klassifikator wäre das die erste Ebene, danach erfolgt die Klassifikation der Abbiegemanöver Ω . Für jede Anfahrtsrichtung, die in Abb. 4.6 dargestellt ist, wurde ein Polynomklassifikator (siehe Abschnitt 4.4.1) auf gelabelten Trajektorienpaaren trainiert. Mit einer Konfidenz-Abbildung [66] (siehe Abschnitt 4.4.2) wurden die Klassifikatorausgaben auf Klassenzugehörigkeitswahrscheinlichkeit $P_\omega(\bar{y}^{(nm)})$ für jede Manöverklasse $\omega \in \Omega$ bestimmt.

Die Gesamtwahrscheinlichkeit $P(\omega)$ für eine Manöverklasse ω ist gegeben durch

$$P(\omega) = \eta_w \sum_{n=1}^N \sum_{m=1}^M \rho^{(nm)} P^{(nm)} P_\omega(\bar{y}^{(nm)}) \quad (4.13)$$

mit η_w als Normalisierungskonstante. Eine Interaktion zwischen den Fahrern wird durch eine Gewichtung $\rho^{(nm)}$ in (4.13) der unabhängigen Verbundwahrscheinlichkeit $P^{(nm)}$ modelliert. Das Modell wird im Abschnitt 4.3.1 vorgestellt.

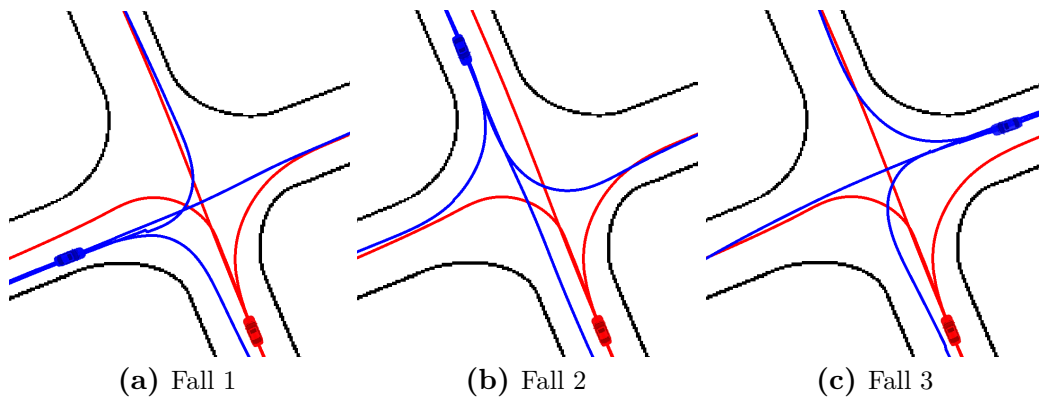


Abbildung 4.6: Unterschiedliche Anfahrts-Richtungen zweier Fahrzeuge mit jeweils drei Manövern (links (L), rechts (R) und der Geradeausfahrt (G)).

4.4.1 Polynomklassifikator

Der Polynomklassifikator [66] nutzt ein Polynom zur Teilung eines Merkmalsraumes in Bereiche, die bestimmten Klassen zugeordnet werden. In unserem Fall handelt es sich um Situationsklassen Ω und der Merkmalsraum wird von den Merkmalsvektoren den Tschebyschow-Koeffizienten $\bar{\mathbf{y}} = (\bar{y}_1, \dots, \bar{y}_N)$ aufgespannt.

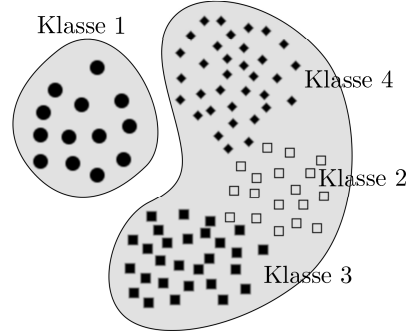


Abbildung 4.7: Die Merkmalsvektoren der Klasse 1 getrennt von restlichen Klassen 2 – 4.

Beim One-vs-All-Prinzip [66] trennt ein Polynom bzw. Diskriminanzfunktion f_ω die Merkmale einer Klasse ω von den Merkmalen der restlichen Klassen ab. Die Abb. 4.7 soll dieses schematisch veranschaulichen. Das Ziel einer Diskriminanzfunktion f_ω ist die Abbildung von Merkmalsvektoren einer Klasse ω auf definierte Diskriminanzwerte. Die reellen Diskriminanzwerte um 1 bedeuten, dass die dazugehörigen Merkmalsvektor zur Klasse ω gehören, während Werte um 0 zu restlichen Klassen gehören.

Als Diskriminanzfunktion f_ω wird ein Polynom des Totalgrades \hat{M} verwendet. Der Totalgrad muss je nach Problem parametrisiert werden. Der Polynom setzt sich aus einem Skalarprodukt eines Koeffizientenvektors $\mathbf{a} = (a_1, \dots, a_{\hat{K}})^T \in \mathbb{R}^{\hat{K}}$ mit dem Unbestimmtenvektor $g(\bar{\mathbf{y}})$

$$f_\omega(\bar{\mathbf{y}}) = \mathbf{a} g(\bar{\mathbf{y}}). \quad (4.14)$$

Der Unbestimmtenvektor erweitert den Merkmalsvektors $\bar{\mathbf{y}}$ auf den \hat{K} -dimensionalen Raum

$$g(\bar{\mathbf{y}}) = \left(1, \bar{y}_1, \bar{y}_2, \dots, \bar{y}_N, \bar{y}_1^2, \bar{y}_1 \bar{y}_2, \dots, \bar{y}_N^{\hat{M}}\right)^T \in \mathbb{R}^{\hat{K}} \quad (4.15)$$

Ein Polynom dritten Totalgrades mit einem dreidimensionalen Unbestimmtenvektor $\bar{\mathbf{y}}$ hat demnach folgende Form

$$\begin{aligned} f_\omega^3(\bar{\mathbf{y}}) = & a_0 + a_1 \bar{y}_1 + a_2 \bar{y}_2 + a_3 \bar{y}_3 + a_4 \bar{y}_1^2 + a_5 \bar{y}_2^2 + a_6 \bar{y}_3^2 + a_7 \bar{y}_1 \bar{y}_2 + a_8 \bar{y}_1 \bar{y}_3 + \\ & + a_9 \bar{y}_2 \bar{y}_3 + a_{10} \bar{y}_1^2 \bar{y}_2 + a_{11} \bar{y}_1^2 \bar{y}_3 + a_{12} \bar{y}_2^2 \bar{y}_1 + a_{13} \bar{y}_2^2 \bar{y}_3 + a_{14} \bar{y}_3^2 \bar{y}_1 + a_{15} \bar{y}_3^2 \bar{y}_2 + \\ & + a_{16} \bar{y}_1^3 + a_{17} \bar{y}_2^3 + a_{18} \bar{y}_3^3 + a_{19} \bar{y}_1 \bar{y}_2 \bar{y}_3. \end{aligned} \quad (4.16)$$

Die Anzahl der Monome werden über den Binomialkoeffizienten aus der Dimension

des Unbestimmtenvektors \bar{N} und des Totalgrades des Polynoms \hat{M} berechnet

$$\hat{K} = \begin{pmatrix} \bar{N} + \hat{M} \\ \hat{M} \end{pmatrix}. \quad (4.17)$$

Mittels einer nichtlinearen Regression erfolgt das "Training" einer Diskriminanzfunktion f_ω für eine Klasse $\omega \in \Omega$. Die Basis dafür ist eine Trainingsmenge, bestehend aus Tupeln von Merkmalsvektoren s mit dazugehörigen Sollausgaben $y_{soll} \in \{1, 0\}$. Bei der Sollausgabe $y_{soll} = 1$ gehört ein Merkmalsvektor einer gewünschten Klasse an und bei $y_{soll} = 0$ gehört der Merkmalsvektor einer der restlichen Klassen an. Die Regression einer Diskriminanzfunktion erfolgt bezüglich des Koeffizientenvektors \mathbf{a} . Eine analytische Lösung des Optimierungsproblems bei der Suche nach dem optimalen Koeffizientenvektor ist

$$\tilde{\mathbf{a}} = (E\{g(\bar{\mathbf{y}})g(\bar{\mathbf{y}})^T\})^{-1} E\{y_{soll}g(\bar{\mathbf{y}})\}, \quad (4.18)$$

wobei $E\{\}$ der Erwartungswert ist.

4.4.2 Konfidenzabbildung

Die nichtlineare Regression einer Diskriminanzfunktion führt zu einem ungewollten Artefakt des Unterschreitens bzw. Überschreitens der gewünschten Sollausgaben, die innerhalb des Intervalls einer Klassenzugehörigkeitswahrscheinlichkeit $[0; 1]$ liegen. Eine Abhilfe für dieses Problem soll die Konfidenzabbildung [66] verschaffen. Durch eine Komposition der Polynomklassifikator-Ausgabe f_ω mit einer Konfidenzabbildung cnf_ω und einer anschließenden Normierung über alle Klassen soll eine Klassenzugehörigkeitswahrscheinlichkeit für die möglichen Situationsklassen erzielt werden.

Auf Basis einer Häufigkeitsverteilung von klassifizierten Merkmalsvektoren soll eine Konfidenzabbildung bestimmt werden. Dazu wird eine Testmenge von Klassifikationsausgaben nach (4.14) in zwei Untermengen aufgeteilt. Die Klassifikationsausgaben der Sollklasse bzw. der Eigenklasse "eigen" bilden die eine Menge und die Ausgaben der restlichen Klassen die Klasse "fremd". Die Häufigkeit der Ausgaben der Klasse eigen für ein Bin mit dem Index \hat{k} ist $hist[\hat{k}|eigen]$. Analog wird die Häufigkeit der fremd-Ausgaben in einem Bin \hat{k} durch $hist[\hat{k}|fremd]$ formuliert. Eine Konfidenzabbildung auf Basis eines Testdatensatzes wird wie folgt für ein Bin \hat{k} approximiert

$$cnf[\hat{k}] = \frac{hist[\hat{k}|eigen]}{hist[\hat{k}|eigen] + hist[\hat{k}|fremd]} = \left(1 + \frac{hist[\hat{k}|fremd]}{hist[\hat{k}|eigen]}\right)^{-1}. \quad (4.19)$$

Dieses entspricht der relativen Häufigkeit der "Treffer" des Bins \hat{k} von eigen-Daten zu Gesamtdaten. Dieser Quotient (4.19) beschränkt wie für eine Darstellung der Wahrscheinlichkeit gewünscht den Bildraum auf das Intervall $[0; 1]$. Ein Array von

$cnf[\hat{k}]$ für alle Bins \hat{k} entspricht einer approximierten Konfidenzabbildung. Dieses Array kann anschließend als Lookup-Abbildung auf die Ausgabe des Polynomklassifikators angewendet werden.

Eine Approximation der Konfidenzabbildung (4.19) für alle \hat{k} über eine Normalverteilung ermöglicht eine glatte und kompakte Repräsentation. Dabei wird der Bildraum mit bisher diskreten Bins \hat{k} durch eine kontinuierliche Diskriminanzvariable \hat{d} ersetzt. Mit folgender Beziehung zwischen einem Histogramm und einer Wahrscheinlichkeit $hist[\hat{k}|eigen] \iff P(\hat{d}|eigen) P(eigen)$ (gilt analog für die *fremd*-Klasse) wird die diskrete Konfidenzabbildung (4.19) in eine Wahrscheinlichkeitsverteilung umformuliert

$$cnf(\hat{d}) = \left(1 + \frac{P(fremd) P(\hat{d}|fremd)}{P(eigen) P(\hat{d}|eigen)} \right)^{-1}. \quad (4.20)$$

Die Histogramme der *eigen*-Klasse und der *fremd*-Klasse werden über je eine Normalverteilung mit einer gemeinsamen Varianz σ und unterschiedlichen Mittelwerten μ_{eigen} und μ_{fremd} angenähert

$$P(\hat{d}|eigen) = N(\mu_{eigen}, \sigma^2) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{1}{2} \left(\frac{\hat{d} - \mu_{eigen}}{\sigma}\right)^2\right), \quad (4.21)$$

$$P(\hat{d}|fremd) = N(\mu_{fremd}, \sigma^2) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{1}{2} \left(\frac{\hat{d} - \mu_{fremd}}{\sigma}\right)^2\right). \quad (4.22)$$

Dieses setzt voraus, dass die Histogramme $hist[\hat{k}|fremd]$ und $hist[\hat{k}|eigen]$ für alle \hat{k} der Normalverteilung ähneln.

Der für die Gleichung (4.20) benötigte Quotient

$$\begin{aligned} \frac{P(\hat{d}|fremd)}{P(\hat{d}|eigen)} &= \exp\left(-\frac{1}{2\sigma^2} \left[(\hat{d} - \mu_{fremd})^2 - (\hat{d} - \mu_{eigen})^2 \right]\right) \\ &= \exp\left(\frac{\mu_{fremd} - \mu_{eigen}}{\sigma^2} \left(\hat{d} - \frac{\mu_{fremd} + \mu_{eigen}}{2}\right)\right). \end{aligned} \quad (4.23)$$

Die kontinuierliche Konfidenzabbildung (4.20) unter Verwendung der Normalverteilungen (4.21) und (4.22) ist eine klassische Sigmoidfunktion in Abhängigkeit von dem Diskriminanzwert \hat{d}

$$cnf(\hat{d}) = \frac{1}{1 + \exp\left(-\alpha_1 \left(\hat{d} - (\alpha_2 + \alpha_3/\alpha_1)\right)\right)}, \quad (4.24)$$

wobei die Koeffizienten wie folgt definiert sind

$$\begin{aligned}\alpha_1 &= \frac{\mu_{eigen} - \mu_{fremd}}{\sigma^2}, \\ \alpha_2 &= \frac{\mu_{eigen} + \mu_{fremd}}{2}, \\ \alpha_3 &= \ln \left(\frac{P(fremd)}{P(eigen)} \right).\end{aligned}\tag{4.25}$$

Für jede Klasse $\omega \in \Omega$ wird nach (4.24) eine Konfidenzabbildungen cnf_ω erzeugt. Eine Klassenzugehörigkeitswahrscheinlichkeit für die Klasse $\omega \in \Omega$ in (4.13) entspricht

$$P_\omega = \left(\sum_{\omega} cnf_\omega(\hat{d}) \right)^{-1} cnf_\omega(\hat{d}),\tag{4.26}$$

wobei \hat{d}_ω durch die entsprechende Diskriminanzfunktion $f_\omega(\bar{y})$ eines Polynomklassifikators substituiert werden kann.

4.4.3 Kollisionswahrscheinlichkeit

Analog zu der Klassifikation der Situationsklassen Ω , lässt sich eine Wahrscheinlichkeit für eine Kollisionsklasse C bestimmen. Die Kollisionswahrscheinlichkeit $P(C)$ ist gegeben durch die folgende Gleichung

$$P(C) = \sum_{n=1}^N \sum_{m=1}^N \rho^{(nm)} P^{(nm)} P(C|X^{(nm)})\tag{4.27}$$

mit $P(C|X^{(nm)}) \in \{1,0\}$, wobei 1 für eine Kollision des Trajektorienpaars (nm) steht und 0 für keine Kollision. Eine effiziente Möglichkeit Kollisionen für Trajektorienpaare zu erkennen wurde im Abschnitt 3.5 beschrieben. Anders als zu der Gefahrenwahrscheinlichkeit aus Abschnitt 3.3 werden hier keine elementaren Fahreraktionen betrachtet, sondern Bewegungsmuster aus dem Realverkehr.

4.5 Evaluation

In dieser Evaluation soll die Güte der Manöverklassifikation auf drei Kreuzungen, die in Abb. 4.8 veranschaulicht werden, bewertet werden. Bei den Testdaten handelt es sich um Sensordaten aus Differential-GPS mit Inertialsensoren, die während einer 10-km-Fahrt im Stadtverkehr aufgezeichnet wurden. Drei vierarmige Kreuzungen K_1 , K_2 and K_3 wurden von einem Fahrer von allen vier Richtungen mit jeweils drei Manövern (L,R und G) abgefahren. Beim Manöver G fuhr der Fahrer gradeaus über die Kreuzung, nach links bog der Fahrer beim Manöver L und nach rechts beim

Manöver R. Diese Einzelmanöver wurden paarweise zu kollisionsfreien Manöverpaaren synchronisiert. Jedes Manöverpaar entspricht einer Situationsklasse Ω . Für die Evaluation wurden für drei Kreuzungen, mit drei möglichen Anfahrt-Richtungen (siehe Abb. 4.6) und jeder Situationsklasse ω zusammen 81 Sequenzen synchronisiert. Da die Einzelmanöver im Realverkehr aufgezeichnet worden sind, sollten die synchronisierten Manöverpaare realistisches Verhalten aufweisen.

Für die Erkennungsgüte wurde ein Referenzzeitpunkt $t_{\text{rec}} = 0$ definiert. Es ist der Zeitpunkt, an dem das letzte Fahrzeug den zum Kreuzungsmittelpunkt nächst gelegenen Punkt erreicht hat. Ab diesem Moment entfernt sich ein Fahrzeug vom Kreuzungsmittelpunkt weg. Für jede Sequenz wurde die Zeit zum Referenzzeitpunkt bestimmt, bei dem zuerst eine Situationsklasse ω nach (4.13) richtig erkannt wurde.




Abbildung 4.8: Der Pfad einer 10-km-Messfahrt auf der Hulb in Böblingen aus einer Vogelperspektive. Drei Kreuzungen K_1 , K_2 und K_3 wurden für die Evaluation gewählt.

Für die Bewegungsprognose wurde eine digitale Karte verwendet, um Trajektorienhypothesen, die den Straßenrand verlassen, als unwahrscheinlich zu klassifizieren. Die Werte der Entscheidungsumgebung ϵ der QRLCS-Distanz (4.1) wurden aus der Bewegungsdatenbank durch die Standardabweichung in jeder Dimension ermittelt und entsprechen $\epsilon = [3,57, 3,57, 1,07, 0,05]$ für Abweichungen in x und y Position, Geschwindigkeit und Gierrate. Der Particle-Filter für die Bewegungsprognose verwendet 50 Particles. Weitere Parameter des Partikel-Filters wurden aus der Arbeit von Hermes [36] übernommen. Der Manöverklassifikator verwendet vier Tschebyschow-Koeffizienten zur Repräsentation einer Trajektorie eines kinematischen Zustandes. Das Interaktionsmodell verfügt über ein Minimum $\rho_{\min} = 0,1$ und die Reaktionszeit

wurde auf $t_r = 1,0$ s gesetzt.

Der Particle-Filter ist ein probabilistischer Ansatz und führt dazu, dass jeder Verlauf zu einem anderen Prognoseergebnis führt. In [36] wurde gezeigt, dass diese Abweichungen vergleichbar klein sind und die Standardabweichung in einem Prognosehorizont von 2 s bei 0,5 m liegt.

Für jede Situationsklasse ω wurde die Wahrscheinlichkeit $P(\omega)$ mit dem Polynomklassifikator gemäß Gl. (4.13) bestimmt. Eine Gewissheit γ_{ω_r} bei der Situationserkennung einer Klasse $\omega_r = \operatorname{argmax}_{\omega \in \Omega} P(\omega)$ wird durch die Differenz zu der Situationsklasse mit der zweitgrößten Wahrscheinlichkeit $\omega_{r2} = \operatorname{argmax}_{\omega \in \Omega \setminus \{\omega_r\}} P(\omega)$ als $\gamma_{\omega_r} = P(\omega_r) - P(\omega_{r2})$ bestimmt. Sobald γ_{ω_r} die empirisch bestimmte Schwelle von 0,2 überschreitet, dann gilt diese Situationsklasse als erkannt.

Tabelle 4.1: Erkennungszeitpunkte t_{rec} der richtigen Situationsklasse für 81 Sequenzen auf drei Kreuzungen (K_1, K_2, K_3). Der Klassenindex bezeichnet die Anfahrtsrichtungen der beiden Fahrzeuge entsprechend den Fällen aus Abb. 4.6.

Klasse	K_1	K_2	K_3	Median	Klasse	K_1	K_2	K_3	Median
GG ₁	-2,54	-3,26	-2,66	-2,66	LR ₁	-1,64	-1,54	-2,96	-1,64
GG ₂	-2,62	-2,20	-2,82	-2,62	LR ₂	-1,68	-1,54	-3,24	-1,68
GG ₃	-1,90	-2,00	-2,12	-2,00	LR ₃	-0,38	-1,28	-1,90	-1,28
GL ₁	-3,18	-1,80	-3,30	-3,18	RG ₁	-0,62	-2,68	-3,68	-2,68
GL ₂	-2,76	-2,22	-2,80	-2,76	RG ₂	-1,24	-3,40	-4,14	-3,40
GL ₃	-2,48	-2,40	-3,08	-2,48	RG ₃	-1,32	-1,28	-2,34	-1,32
GR ₁	-3,20	-1,08	-3,64	-3,20	RL ₁	-1,52	-1,10	-2,36	-1,52
GR ₂	-2,24	-2,06	-1,50	-2,06	RL ₂	-1,86	-1,88	-1,62	-1,86
GR ₃	-1,56	-2,08	-1,68	-1,68	RL ₃	-0,28	-1,36	-1,72	-1,36
LG ₁	-2,90	-1,46	-3,86	-2,90	RR ₁	-1,82	-2,32	-2,12	-2,12
LG ₂	-2,50	-1,10	-2,66	-2,50	RR ₂	-1,70	-1,56	-3,78	-1,70
LG ₃	-2,58	-1,20	-0,96	-1,20	RR ₃	-1,88	-2,44	-0,64	-1,88
LL ₁	-1,02	-1,52	-4,49	-1,52					
LL ₂	-1,68	-1,38	-3,56	-1,68					
LL ₃	-1,48	-0,50	-1,12	-1,12					

Tabelle 4.1 veranschaulicht die Erkennungszeitpunkte t_{rec} für 81 Sequenzen, ab denen die Situation nach dem Kriterium γ_{ω_r} richtig erkannt wurde. Bei der Notation einer Situationsklasse z.B. GG₁ entspricht der Index (1) den Fall nach Abb.4.6 bzw. die relative Zufahrtsrichtung beider Fahrzeuge. Die Evaluation der Daten für jede Kreuzung K_n wurden nach dem Prinzip des Auslassens der anderen beiden Kreuzungen

$K_{m \neq n}$ durchgeführt. Die Werte in der Tabelle 4.1 wurden aus einzelnen Durchläufen des Partikel-Filters abgeleitet. Bei mehreren Durchläufen einer Sequenz liegt eine Standardabweichung der Zeit t_{rec} bei 0,3 s. Die negativen Erkennungszeitpunkte t_{rec} deuten darauf hin, dass alle 81 Situationen am Ende erfolgreich erkannt wurden. Einige Situationen wurden relativ später erkannt, speziell an der Kreuzung K_1 , weil die Spuren breiter sind und damit der Abbiegevorgang später startet. Der Median der Erkennungszeitpunkte t_{rec} liegen zwischen $-1,12$ s und $-3,4$ s.

4.5.1 Einfluss der gegenseitigen Sichtbarkeit

Eine typische gefährliche Situation entsteht, wenn ein Fahrzeug die Vorfahrt des anderen missachtet. Zwei leicht unterschiedliche Sequenzen mit einer Kollision am Ende sind in Abb. 4.9 dargestellt. Die Kollisionserkennung (4.27) steigt im Szenario 2 0,2 s früher an und endet bei $P(C) = 1$. Die Ursache für diesen frühen Anstieg ist, dass in Szenario 2 die gegenseitige Sichtbarkeit in der Sequenz schlechter ist. Im Szenario 2 biegt der Fahrer früher ab und legt den Fokus auf die abzubiegende Straße und weniger auf den Entgegenkommer. Im Szenario 1 liegt der Fokus der Fahrer, der auf den Prognosen basiert, mehr aufeinander als im Szenario 2. Zudem wurde die richtige Situationsklasse ω für beiden Szenarien bei $t_{\text{rec}} = -1,30$ s und $t_{\text{rec}} = -1,84$ s erkannt.

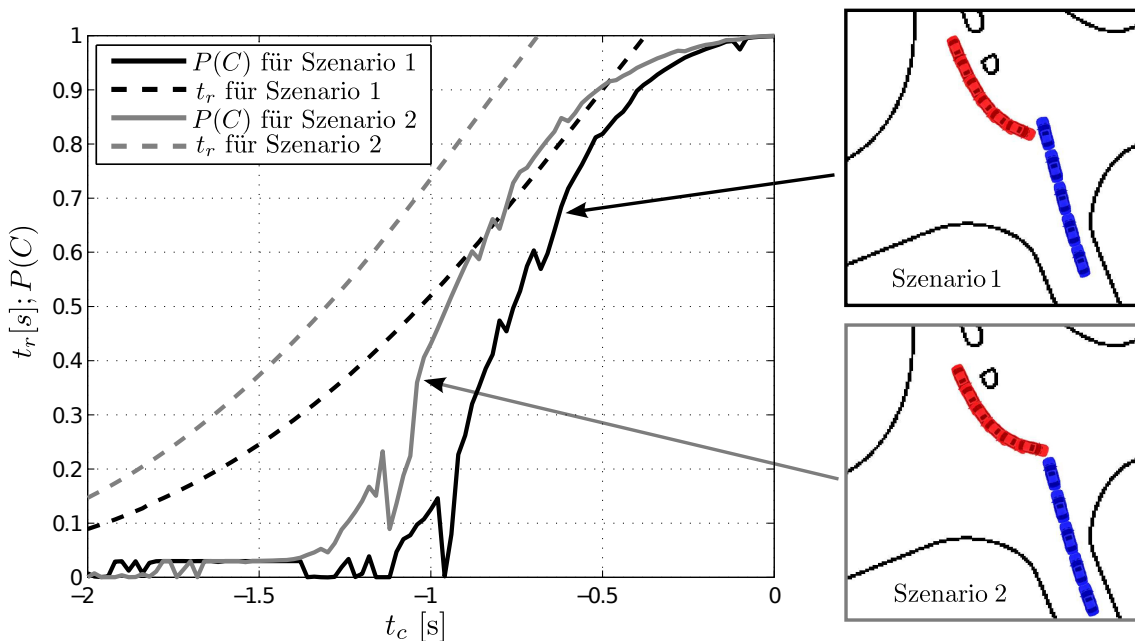


Abbildung 4.9: Unterschiede beim Verlauf der Gefahrenwahrscheinlichkeit für zwei Kollisionsszenarien, die aus unterschiedlicher Sichtbarkeit nach (4.12) der Fahrer resultieren. Die schlechtere Sichtbarkeit im Szenario 2 führt zu einem früheren Gefahrenanstieg.

4.6 Zusammenfassung

Das Ziel einer Interaktion zwischen den Fahrern ist die Vermeidung von Kollision im Straßenverkehr. Andererseits kann auf Basis der Kritikalitätsbewertung überprüft werden, ob eine Interaktion stattfinden könnte. In diesem Abschnitt wurde ein Interaktionsmodell eingeführt, um zwei unabhängige Einzeltrajektorienprognosen zu einer gemeinsamen Prognose zu vereinen. Der Fokus des Interaktionsmodells liegt auf Hypothesenpaaren, die zu einer Kollision führen. Mit der Annahme, dass beide Fahrer die kollisionsfreien Hypothesenpaare bevorzugen, wird die Wahrscheinlichkeit für Kollisionspaare verringert. Deswegen werden die Hypothesenpaare bei der Kritikalitätsbewertung auf gegenseitige Sichtbarkeit der Fahrer analysiert. Der Einfluss der gegenseitigen Sichtbarkeit stuft Situationen, in denen die Fahrer nicht im gegenseitigen Blickfeld sind, früher als kritisch ein.

Auf Basis von real beobachteten Trajektorien konnte dieser Prognoseansatz für Situationsklassifikation auf Kreuzungen evaluiert werden. Die Erkennungszeitpunkte der richtigen Situation sind in allen Sequenzen ein paar Sekunden bevor beide Fahrzeuge den Kreuzungsmittelpunkt passiert haben. Der Vorteil eines Interaktionsmodells liegt in der Bewertung von prognostizierten Kollisionen, die aus einer unabhängig voneinander für jedes einzelne Fahrzeug aufgestellten Prognose hervorgehen. Damit behalten prognostizierte Kollisionstrajektorien nur in kritischen Situationen ihre unabhängige Eintrittswahrscheinlichkeit. In unkritischen Situationen wird diese verringert. Der Fokus des Fahrers wird in Fahrtrichtung angenommen, was aber in einer realen Situation nicht gelten muss. Deshalb kann der Fokus des Fahrers in einem erweiterten Ansatz durch eine Fahrerbeobachtung mit einer Kamera geschätzt werden.

Ein Modell zur Bewegungsprognose zweier Fahrzeuge ohne das Interaktionsmodell, jedoch auch für Trajektorienpaare wird im nächsten Kapitel vorgestellt. Die Interaktion der Fahrzeuge liegt dort bereits in den Daten vor. Der Unterschied zu dem in diesem Kapitel beschriebenen Ansatz besteht darin, dass das interagierende Verhalten in Form von Trajektorienpaaren aufgezeichnet wird.

Bewegungsprognose von interagierenden Fahrzeugen

5.1 Zielstellung

Während einer Interaktion zwischen zwei Fahrern wird das Verhalten eines Fahrers vom jeweils anderen beeinflusst. Eine Interaktion zwischen zwei Fahrern entsteht häufig beim amerikanischen Abbiegen LL auf relativ schmalen Kreuzungen. Wenn die Abbiegespur nicht markiert ist, dann müssen beide Fahrer einen Weg finden, um sicher aneinander vorbei zufahren. Eine Interaktion zwischen zwei Fahrern muss nicht nur in unkritischen Situationen erfolgen. Ein Ausweichmanöver eines Fahrers, der die Vorfahrt eines anderen missachtet, entspricht ebenfalls einem Interaktionsverhalten. Das Ziel des interagierenden Verhaltens ist in den meisten Fällen die Vermeidung von Kollisionen mit anderen Verkehrsteilnehmern. In der frühen Phase einer Begegnung zweier Fahrzeuge kann eine Interaktion als ein Indiz für einen unkritischen Verlauf der Situation verwendet werden.

Im Kapitel 4 besteht die Wissensbasis aus einer Datenbank mit Trajektorien *eines* Fahrzeugs. Bei einer Erweiterung der Prognose auf zwei Fahrzeuge wurde zusätzlich ein Interaktionsmodell eingeführt, das die Interaktion der Fahrer berücksichtigt. Alternativ zu einem Interaktionsmodell soll in diesem Kapitel eine Wissensbasis mit Trajektorien zweier Fahrzeuge betrachtet werden. Eine Betrachtung der gekoppelten Bewegung zweier Fahrzeuge impliziert per se die Interaktion. Als Input für die Wissensbasis werden aufgezeichnete Kreuzungsszenarien mit zwei Fahrzeugen, die eine vierarmige Kreuzung passieren, verwendet. Dieser Datensatz an Szenarien wurden bereits im Abschnitt 3.6 zur Bestimmung einer Feel-Safe-Zone verwendet. Die Sequenzen werden in unterschiedliche Situationsklassen (siehe Abb. 3.10) aufgeteilt und klassenindividuell für eine kompakte Repräsentation in Form einer Mannigfaltigkeit aufbereitet. In Abb. 5.1 werden einzelne Schritte der Datenaufbereitung aufgezeigt. Im ersten Schritt werden aus Sequenzen beliebiger Dauer alle möglichen Trajektorienpaare einer festen Dauer extrahiert. Die Länge der Trajektorienpaare

entspricht dem Prognosehorizont der Bewegungen beider Fahrzeuge. Eine kompakte und stetige Repräsentation der diskreten Bewegungsmuster wird im ersten Schritt mit einer Zerlegung in Tschebyschow-Polynome [15] erzielt. Anschließend werden die Tschebyschow-Vektoren eines Trajektorienpaares zu einem Merkmalsvektor aneinandergereiht. Die Merkmalsvektoren werden klassenspezifisch mit einem Cluster-Ansatz [21], [52] auf eine repräsentative Menge ausgedünnt. Für jede Situationsklasse wird das interagierende Abbiegeverhalten zweier Fahrzeuge mit Hilfe einer nichtlinearen Regression über eine niedrigdimensionale Mannigfaltigkeit repräsentiert. Nach der Theorie der Neuronalen Netzen entspricht dieser Vorgang einem unüberwachten Lernprozess [63], [10]. Die Erzeugung einer Wissensbasis in Form von

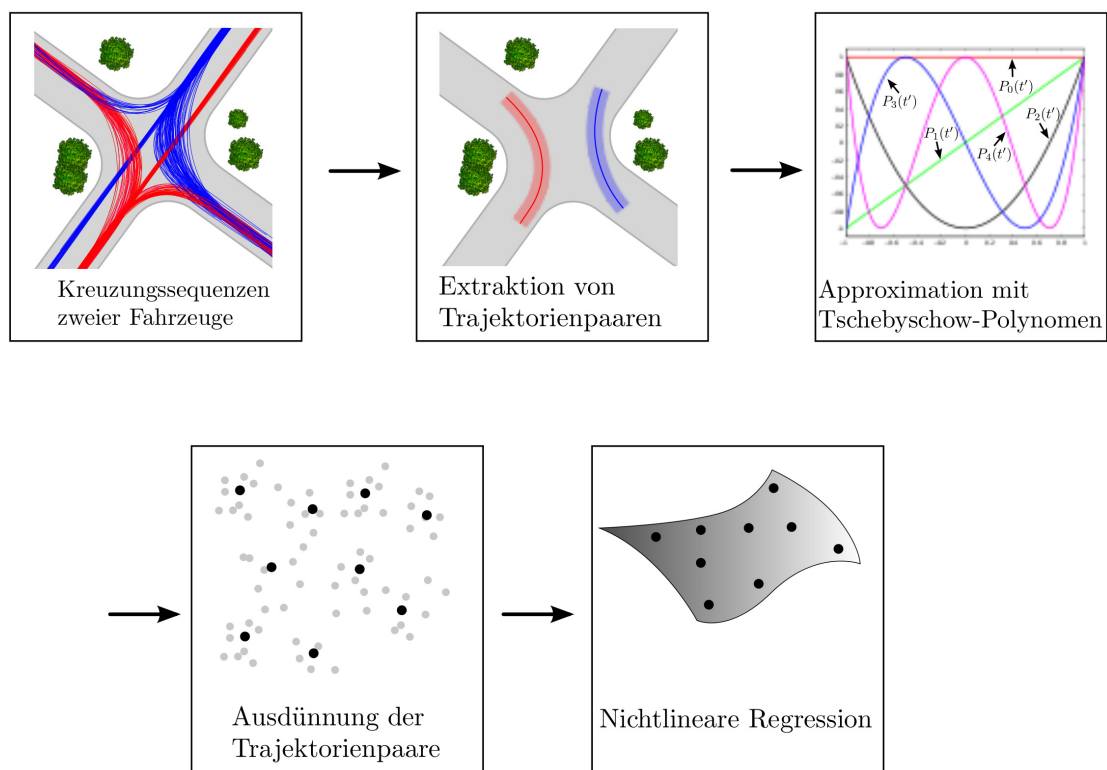


Abbildung 5.1: Datenaufbereitung und Analyse von interagierenden Bewegungsmustern zweier Fahrzeuge.

klassenspezifischen Mannigfaltigkeiten entspricht einer Trainingsphase, die z.B. im Labor durchgeführt werden kann. Einen mannigfaltigkeitsbasierten Ansatz zur Prognose der Bewegung eines Fahrzeugs haben bereits Hermes et al. [35] [33] vorgestellt. In diesem Ansatz soll anstatt Einzeltrajektorien Trajektorienpaare klassenspezifisch über Mannigfaltigkeiten dargestellt werden und somit mehr Information über eine Kreuzungssituation in die Wissensbasis integriert werden. Es wird in diesem Ansatz anders als in [35] oder im Kapitel 4 auf eine Bewegungshistorie verzichtet und durch einen aktuellen Zustand von zwei Fahrzeugen ersetzt.

Eine Situation zwischen zwei Fahrzeugen ist durch ihre jeweilige Position und den jeweiligen kinematischen Zuständen definiert. Auf Basis dieser beobachteten Situation sollen die zuvor erzeugten Mannigfaltigkeiten nach ähnlichen Situationen abgesucht werden. Die Mannigfaltigkeiten bestehen jedoch aus gekoppelten Bewegungsmustern, bzw. Folgen von Situationen. Dazu wird in jedem Bewegungsmuster nur die Startsituation zum Vergleich herangezogen (siehe Abb. 5.2). Der restliche Verlauf fungiert später als Bewegungsprognose.

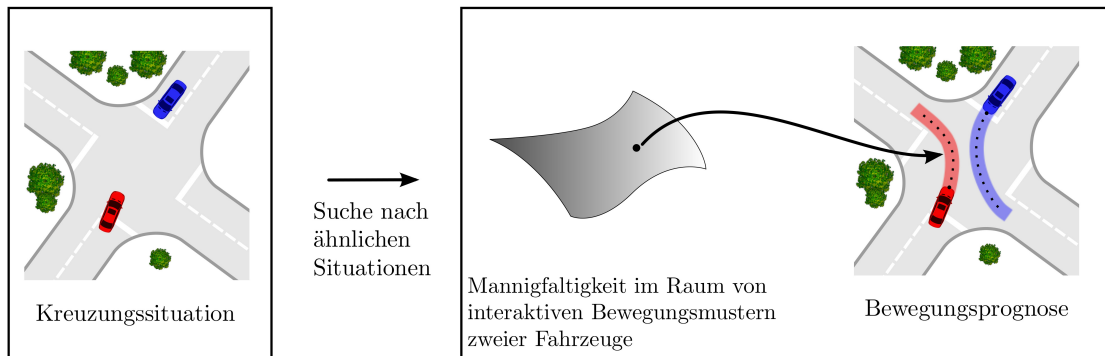


Abbildung 5.2: Bewegungsprognose mit Interaktion auf Basis einer Wissensbasis in Form einer Mannigfaltigkeit aus Bewegungspaaren. Die Startsituation (Fahrzeuggabbildungen) eines interagierenden Bewegungsmusters mit Fortsetzung (Fahrspur) fungiert als Bewegungsprognose.

Im Abschnitt 5.2 wird auf die Merkmalsextraktion aus den Trajektorienpaaren mit Hilfe der Tschebyschow-Polynome eingegangen. Die Ausdünnung einer Trainingsmenge erfolgt mittels des Lloyd-Algorithmus im Abschnitt 5.3. Mit dem Ziel klassenspezifische Mannigfaltigkeiten (Abschnitt 5.5) zu erzeugen wird im Abschnitt 5.4 die *Unsupervised Kernel Regression* (UKR) ein nichtlineares Regressionsverfahren betrachtet. Die Bewegungsprognose erfolgt über die k -nächsten-Nachbar-Suche nach ähnlichen Situationen im Abschnitt 5.6. In der abschließenden Evaluation im Abschnitt 5.7 wird die Situationsklassifikation und Prognosegenauigkeit des Ansatzes ausgewertet.

5.2 Bewegungsrepräsentation

Eine Reihe von beobachteten Szenarien zwischen zwei Fahrzeugen \mathcal{A} und \mathcal{B} sind in Form von Trajektorienpaaren $(x_{\mathcal{A}}^{(i)}, y_{\mathcal{A}}^{(i)}, x_{\mathcal{B}}^{(i)}, y_{\mathcal{B}}^{(i)}, t^{(i)})$ mit der Eigenschaft einer zeitlich äquidistanten Folge $t^{(i+1)} - t^{(i)} = t^{(i)} - t^{(i-1)}$ gegeben. Die Repräsentation der Trajektorien erfolgt bezüglich eines festen Kreuzungskoordinatensystems (siehe Abb. 5.3a). Der Bewegungsraum der Fahrzeuge ist auf einen Kreuzungstyp, in unserem Fall eine vierarmige Kreuzung, beschränkt. Der Einsatz eines Kreuzungskoordinatensystems setzt voraus, dass der Mittelpunkt und die Orientierung der Kreuzung bekannt sind und eine Lokalisierung der beiden Fahrzeuge möglich ist. Das Kreuzungskoordinatensystem nutzt die Symmetrie dieser vierarmigen Kreuzung aus, um z.B. ein

mögliches Abbiegemanöver eines auf die Kreuzung zufahrenden Fahrzeugs über eine 180-Grad-Rotation um den Kreuzungsmittelpunkt eines von der entgegengesetzten Seite kommenden Fahrzeugs zu beschreiben.

Zur Extraktion aller möglichen Prognosetrajektorienpaaren aus einer Kreuzungssequenz kommt das Shift-Window-Prinzip zum Einsatz. Dabei wird ein Zeitfenster über eine Sequenz geschoben und alle im Zeitfenster liegende Trajektorienabschnitte ausgeschnitten. Dies setzt voraus, dass eine Sequenz länger als das Zeitfenster ist. Die Abb. 5.3b visualisiert eine zerlegte Sequenz eines amerikanischen Abbiegevorgangs zweier Fahrzeuge. Aus dieser Sequenz wurden sukzessive 68 Trajektorienpaare mit jeweils einem Fenster von 2,52 s ausgeschnitten und gegen den Zeitpunkt 0 referenziert. Diese Trajektorienpaare fungieren später als Referenzmuster für die Bewegungsprognose eines amerikanischen Abbiegevorgangs.

Für die Erzeugung eines Trainingsdatensatzes sollen zuvor aufgezeichnete Bewegungsmuster zweier Fahrzeuge in eine kompaktere Form transformiert werden. Eine Trajektorie der x -Position in diskreter Form $x^{(i)}$ besteht je nach Länge \hat{N} und Schrittweite aus einem \hat{N} -dimensionalen Array. Beispielsweise verfügt eine Trajektorie einer Dauer von 2,52 s mit einer Schrittweite von 0,04 s über insgesamt 63 Zustände. Bei einer Repräsentation der Positionstrajektorien zweier Fahrzeuge ergibt die Aneinandereiung der 4-Trajektorien (für jedes Fahrzeug je x - und y -Position) einen 252-dimensionalen Vektor, der bzgl. des numerischen Handlings als rechenintensiv einzustufen ist.

Eine Tschebyschow-Zerlegung [15] bietet die Möglichkeit solche diskreten Trajektorien durch Polynome zu approximieren. Der Vorteile liegt nicht nur in der Kompression der Bewegung, sondern ermöglicht aufgrund der Stetigkeit eines Polynoms die Berechnung beliebiger Ableitungen an beliebigen Stellen der Trajektorie. Auf Basis einer Positionstrajektorie $(x^{(i)}, y^{(i)})$ kann die Geschwindigkeit oder die Beschleunigung des Fahrzeugs abgeleitet werden. Bei zwei Fahrzeugen \mathcal{A} und \mathcal{B} werden je Dimension von insgesamt vier Trajektorien $x_{\mathcal{A}}^{(i)}, y_{\mathcal{A}}^{(i)}, x_{\mathcal{B}}^{(i)}, y_{\mathcal{B}}^{(i)}$ für $i = 0, \dots, \hat{N}$ über die Tschebyschow-Polynome approximiert. Jede Approximation einer Trajektorie ergibt je nach Approximationsgenauigkeit eine Reihe von Tschebyschow-Koeffizienten. Die Tschebyschow-Koeffizienten der vier Dimensionen werden zu einem Merkmalsvektor

$$\bar{\mathbf{y}} = (\mathbf{c}_{\mathcal{A},x}, \mathbf{c}_{\mathcal{A},y}, \mathbf{c}_{\mathcal{B},x}, \mathbf{c}_{\mathcal{B},y}) \quad (5.1)$$

zusammengefasst. Eine genaue Beschreibung der Tschebyschow-Zerlegung folgt im nächsten Abschnitt.

5.2.1 Approximation mit Tschebyschow-Polynomen

Mit einer Tschebyschow-Approximation soll eine diskrete Trajektorie (x_i, t_i) mit $i = 0, \dots, \hat{N}$ in den Raum von orthogonalen Basisfunktionen, den Tschebyschow-

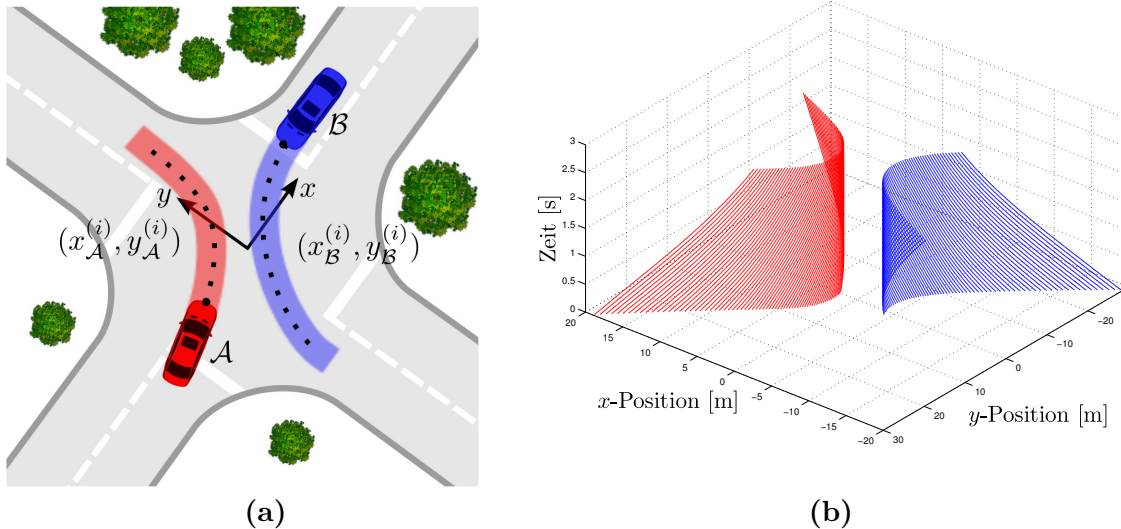


Abbildung 5.3: (a) Zwei Positionstrajektorien $(x_A^{(i)}, y_A^{(i)})$ und $(x_B^{(i)}, y_B^{(i)})$ bezüglich des Kreuzungskoordinatensystems (x, y) im Kreuzungsmittelpunkt. (b) Eine Sequenz eines "amerikanischen Abbiegevorgangs" wurde nach dem Shift-Window-Prinzip in eine Schar von Trajektorienpaaren zerlegt.

Polynomen, transformiert werden. Eine lineare Kombination der Tschebyschow-Polynome soll jedes diskrete Bewegungsmuster, wie in Abb. 5.3b veranschaulicht, eines Fahrzeugs hinreichend genug approximieren.

Bezüglich der Zeit liegt der Definitionsbereich einer Trajektorie für die Tschebyschow-Zerlegung im Intervall $[-1, 1] \in \mathbb{R}$. Wenn eine Trajektorie nicht innerhalb des Intervalls liegt, d.h. $t_0 \neq -1$ und $t_{\hat{N}} \neq 1$, dann ist eine Skalierung der Trajektorie auf das Intervall $[-1, 1]$ erforderlich. Die Umrechnung der Zeitpunkte t_i in skalierte Zeitpunkte t'_i kann wie folgt vorgenommen werden

$$t'_i = \frac{2t_i}{t_{\hat{N}} - t_0} - \frac{t_{\hat{N}} + t_0}{t_{\hat{N}} - t_0}. \quad (5.2)$$

Bei dieser Skalierung werden die Zeitstempel t_i einer Trajektorien durch neue Zeitstempel t'_i ersetzt.

Meistens enthalten Bewegungstrajektorien einen chronologischen Verlauf der Zustände mit äquidistanten Abständen. Eine Tschebyschow-Approximation auf äquidistanten Stützstellen t'_i würde zu dem unerwünschten Runge-Phänomen [55] führen, bei dem sich an beiden Intervallenden das Polynom aufschwingt. Zur Vermeidung des Phänomens werden in nicht äquidistanten Abständen die Cauchy-Gauß-Stützstellen bestimmt. Die Cauchy-Gauß-Stützstellen liegen nicht auf den Trajektorienpunkten und können über eine Interpolation berechnet werden. Eine Möglichkeit eine Trajek-

torie zu interpolieren, ist die Definition einer Intervallfunktion. Dazu zerlegt man das Intervall $[-1,1]$ in \hat{N} disjunkte Teilintervalle

$$T'_i = \begin{cases} [-1, \frac{t'_1+t'_2}{2}) & \text{falls } i = 1 \\ (\frac{t'_{i-1}+t'_i}{2}, \frac{t'_i+t'_{i+1}}{2}) & \text{falls } 1 \leq i \leq \hat{N} - 1 \\ (\frac{t'_{\hat{N}-1}+t'_{\hat{N}}}{2}, 1] & \text{falls } i = \hat{N}. \end{cases} \quad (5.3)$$

Die Intervallfunktion repräsentiert eine stückweise konstante Funktion

$$f_x(t') = x_i \text{ wenn } t' \in T'_i \text{ (für } 1 \leq i \leq \hat{N} \text{)}. \quad (5.4)$$

Dieses Interpolationsverfahren wird auch die Nächster-Nachbar-Interpolation genannt. In der Praxis hängt die Wahl eines Interpolationsverfahrens von der Anzahl der Stützstellen \hat{N} ab. Bei relativ vielen Stützstellen, wie es in unserem Fall sein wird, reicht eine Nächste-Nachbar-Interpolation aus. Bei wenig Stützstellen wird zu genaueren Interpolationsverfahren, wie lineare Interpolation oder Spline-Interpolation [71], geraten.

Als nächstes soll eine Trajektorie in Form einer stückweise konstanten Funktion $f_x(t')$ durch eine Summe von gewichteten Tschebyschow-Polynomen $G_i(t') = \cos(\hat{l} \arccos(t'))$ approximiert werden. Eine Approximation mit $\hat{L} + 1$ Tschebyschow-Polynomen ist wie folgt formuliert

$$f_x(t') \approx \sum_{i=0}^{\hat{L}} c_i G_i(t'), \quad (5.5)$$

wobei c_i der Gewichtungskoeffizient ist, den es bei der Approximation zu bestimmen gilt. Ein Tschebyschow-Polynom beliebigen Grades lässt sich für alle $k \geq 2$ mit den Startpolynomen $G_0(t') = 1$ und $G_1(t') = t'$ rekursiv wie folgt bestimmen

$$G_i(t') = 2t' G_{i-1}(t') - G_{i-2}(t'). \quad (5.6)$$

Zur Bestimmung der Gewichtskoeffizienten für die Approximationsfunktion (5.5) werden \hat{N} Tschebyschow-Gauß-Stützstellen [55] t'_δ verwendet

$$c_{\hat{l}} = \frac{2}{\hat{N}} \sum_{\delta=1}^{\hat{N}} f_x(t'_\delta) G_{\hat{l}}(t'_\delta) \text{ für } \hat{l} \geq 1. \quad (5.7)$$

Um einen Kompressionseffekt zu erzielen, wird die Berechnung der Gewichtskoeffizienten auf $\hat{L} \ll \hat{N}$ reduziert. Damit sollen weniger Polynome zur Approximation verwendet werden als es Stützstellen gibt. Dieses setzt natürlich voraus, dass der anschließende Approximationsfehler genügend klein bleibt. Die Repräsentation

einer \hat{N} -dimensionalen diskreten Trajektorie durch eine Menge von Tschebyschow-Koeffizienten $\{c_0, \dots, c_{\hat{L}}\}$ soll das Ziel sein.

Eine Approximation einer realen Trajektorie der x -Position eines Fahrzeugs über 2,52 s veranschaulicht die Abb. 5.4. Die diskrete Trajektorie (mit Kreuzchen) ver-




Abbildung 5.4: Approximation einer x -Position-Trajektorie mit den ersten 8 Tschebyschow-Polynomen. Der Approximationsfehler an den Trajektorienpunkten beträgt $0,000317 \pm 0,0019$ m.

fügt über einen Abtastungsabstand von 0,04 s und ist somit 63-dimensional. Eine Tschebyschow-Approximation der Ordnung 7 approximiert diese Trajektorie mit einem mittleren Fehler von $0,000317 \pm 0,0019$ m an den Trajektorienpunkten und ist für unsere Anwendung vernachlässigbar klein. Der Verlauf der diskreten Beispieltrajektorie weist wenige Schwingungen auf und lässt sich gut durch niedrigdimensionale Polynome approximieren. Eine Tschebyschow-Approximation der Ordnung 7 besteht aus 8 Gewichtskoeffizienten, die die Approximationsfunktion beschreiben. Der Benefit dieser Approximation ist eine Reduktion von 63 diskreten Stützstellen einer diskreten Trajektorie auf 8 Gewichtskoeffizienten, d.h. Faktor 7,875 weniger Daten. Zusätzlich erhält man mit den Tschebyschow-Polynomen stetige und differenzierbare Funktionen.

Bei der Approximation einer Trajektorie (z.B. x -Position) durch ein Tschebyschow-Polynom mit \hat{L} Koeffizienten beträgt die Zeitkomplexität $O(\hat{L} \hat{N})$.

5.3 Lloyd-Algorithmus

Um die Trainingsmenge auf eine repräsentative Menge auszdünnen, soll hierbei der *Lloyd-Algorithmus* [52], ein Typ des *k-Means-Algorithmus*, zum Clustern der Trajektorienchnipsel angewendet werden. Genauer sollen die Merkmalsvektoren aus Tschebyschowkoeffizienten $\bar{\mathbf{y}}$ entsprechend (5.1) in \hat{K} disjunkte Teilmengen $S_{\hat{k}}$ (Cluster) mit $\hat{k} = 1, \dots, \hat{K}$ aufgeteilt werden. Die Mittelwerte der Cluster $\boldsymbol{\mu}_{\hat{k}}$ werden als Repräsentanten aller Merkmalsvektoren in das Trainingsset für die anschließende Regression, siehe Abschnitt 5.4, aufgenommen.

Bei der Aufteilung der Merkmalsvektoren in Cluster gilt es einen quadratischen Fehler zu minimieren. Dieser hängt von dem Abstand der Cluster-Elemente zu dem Mittelwert $\boldsymbol{\mu}_{\hat{k}}$ eines Clusters ab. Die Summe der quadratischen Fehler über alle Cluster ergibt eine Fehlerfunktion

$$F_E = \sum_{\hat{k}=1}^{\hat{K}} \sum_{\bar{\mathbf{y}} \in S_{\hat{k}}} \|\bar{\mathbf{y}} - \boldsymbol{\mu}_{\hat{k}}\|^2. \quad (5.8)$$

Der Lloyd-Algorithmus ist ein Ansatz zur Minimierung dieser Fehlerfunktion und wird in folgenden Schritten abgearbeitet:

1. Initialisierung: Setze \hat{K} zufällige Mittelwerte im initialen Durchlauf (1): $\boldsymbol{\mu}_1^{(1)}, \dots, \boldsymbol{\mu}_{\hat{K}}^{(1)}$
2. Zuweisung: Jeder Merkmalsvektor $\bar{\mathbf{y}}$ wird dem nächsten Cluster aus dem Durchlauf (s) zugewiesen

$$S_{\hat{k}}^{(s)} = \left\{ \bar{\mathbf{y}} : \left\| \bar{\mathbf{y}} - \boldsymbol{\mu}_{\hat{k}}^{(s)} \right\| \leq \left\| \bar{\mathbf{y}} - \boldsymbol{\mu}_{\hat{k}^*}^{(s)} \right\| \text{ für alle } \hat{k}^* = 1, \dots, \hat{K} \right\}. \quad (5.9)$$

3. Update: Berechne neue Mittelpunkte der Cluster

$$\boldsymbol{\mu}_{\hat{k}}^{(s+1)} = \frac{1}{|S_{\hat{k}}^{(s)}|} \sum_{\bar{\mathbf{y}} \in S_{\hat{k}}^{(s)}} \bar{\mathbf{y}}. \quad (5.10)$$

Die Anzahl der Elemente eines Clusters \hat{k} im Durchlauf (s) ist durch die Mächtigkeit $|S_{\hat{k}}^{(s)}|$ der Menge bestimmt.

4. Abbruchbedingung: Kein Datum wurde einem neuen Cluster zugewiesen.

Dieser Algorithmus garantiert nicht das Finden eines globalen Minimums. Die Lösung hängt stark von den gewählten Start-Mittelwerten im Initialisierungsschritt ab. Ein möglicher elementarerer Ansatz ist eine zufallsgenerierte Initialisierung der Start-Mittelwerte, so dass die totale Varianz der Daten am kleinsten ist.

Die Merkmalsvektoren werden klassenspezifisch ausgedünnt, d.h. für jede Situationsklasse separat. Das Ergebnis einer Ausdünnung von Merkmalsvektoren ist eine Reduktion von zukünftigen Trainingsdaten auf wenige Repräsentative. Die Trainingsdaten-Reduktion soll den Rechenaufwand für die folgende Regression aus Abschnitt 5.4 gering halten.

5.4 Niedrigdimensionale Repräsentation

Unsere Beobachtungen liegen in Form einer Menge von Merkmalsvektoren $\bar{\mathbf{Y}} = (\bar{\mathbf{y}}_1, \bar{\mathbf{y}}_2, \dots, \bar{\mathbf{y}}_M) \in \mathbb{R}^{d \times M}$ vor. Die Merkmalsvektoren entsprechen den aneinandergereihten Tschebyschow-Koeffizienten, die die Bewegung zweier Fahrzeuge mit einer begrenzten Dauer beschreiben. Für diese Merkmalsvektoren gilt es mittels Optimierungsverfahren eine niedrigdimensionale Repräsentation in Form von latenten Variablen $\bar{\mathbf{X}} = (\bar{x}_1, \bar{x}_2, \dots, \bar{x}_M) \in \mathbb{R}^{q \times M}$ mit einer funktionalen Abhängigkeit $\bar{\mathbf{y}} = \mathbf{f}(\bar{\mathbf{x}})$ zu finden (siehe Abb. 5.5). Der Raum um die latenten Variablen $\bar{\mathbf{X}}$ wird als eine niedrigdimensionale Mannigfaltigkeit betrachtet und entspricht einer kompakten Repräsentation des Wissens. Die selbstorganisierenden Merkmalskarten [47], [63] sind ein verbreiteter Ansatz aus dem Bereich der Neuronalen Netze zur Findung einer niedrigdimensionalen Mannigfaltigkeit, die den inhärenten Zusammenhang einer Mustermenge beschreibt.




Abbildung 5.5: Beispiel: Eine eindimensionale Mannigfaltigkeit \bar{x} zieht sich durch eine Datenmenge im zweidimensionalen Beobachtungsraum. Jede Beobachtung $\bar{\mathbf{y}}_i$ wird im latenten Raum durch eine latente Variable \bar{x}_i repräsentiert.

5.4.1 Unsupervised Kernel Regression

Unsupervised Kernel Regression (UKR) ist ein Ansatz zum "Lernen" von kontinuierlichen nichtlinearen Mannigfaltigkeiten. Es wurde als eine unüberwachte Formulierung des Nadaraya-Watson-Schätzers von Meinecke et al. [56] vorgestellt und wurde von Klanke [44] weiter entwickelt. Der Nadaraya-Watson-Schätzer beschreibt eine Abbildung $\bar{\mathbf{y}} = \mathbf{f}(\bar{\mathbf{x}})$ von dem latenten Raum in den Beobachtungsraum

$$\bar{\mathbf{y}} = \mathbf{f}(\bar{\mathbf{x}}) = \sum_{i=1}^M \bar{\mathbf{y}}_i \frac{K_{\mathbf{H}}(\bar{\mathbf{x}} - \bar{\mathbf{x}}_i)}{\sum_j K_{\mathbf{H}}(\bar{\mathbf{x}} - \bar{\mathbf{x}}_j)}. \quad (5.11)$$

Dieser Schätzer ermöglicht eine stetige und glatte Generalisierung einer funktionalen Beziehung zwischen den Variablen $\bar{\mathbf{x}}$ und $\bar{\mathbf{y}}$ auf Basis einer Trainingsmenge $(\bar{\mathbf{x}}_i; \bar{\mathbf{y}}_i)$. Die Funktion $K(\cdot)$ ist eine Kernel-Dichtefunktion mit der dazugehörigen Bandbreite \mathbf{H} .

Für die hier vorliegende Aufgabenstellung hat sich das Gauß-Kernel als geeignet herausgestellt

$$K_{\mathbf{H}} = \frac{1}{\det(\mathbf{H})} K(\mathbf{H}^{-1}\bar{\mathbf{x}}) = \frac{1}{(2\pi)^{\frac{q}{2}} \det(\mathbf{H})} \exp\left(-\frac{1}{2} \|\mathbf{H}^{-1}\bar{\mathbf{x}}\|^2\right). \quad (5.12)$$

Die Gleichung (5.11) ist eine Abbildung aus dem latenten Raum $\bar{\mathbf{x}}$ in den ursprünglichen Raum der beobachteten Daten, in dem die Mannigfaltigkeit eingebettet ist und aus dem die Daten $\bar{\mathbf{Y}} = \{\bar{\mathbf{y}}_i\}, \hat{i} = 1..M$ beobachtet wurden. Die latenten Stützstellen $\bar{\mathbf{X}} = \{\bar{\mathbf{x}}_i\}, \hat{i} = 1..M$ fungieren als Parametersatz bei der Regression (5.11), der unüberwacht "gelernt" werden soll. Die latenten Variablen entsprechen einem generalisierten Wissen über die beobachteten Daten $\bar{\mathbf{Y}}$. Die Skalierung und Positionierung der Stützstellen $\bar{\mathbf{x}}_i$ ist frei und folgt aus dem Lernprozess. Mit Hilfe von Optimierungsverfahren bzw. Lernvorgängen werden die Stützstellen bestimmt. Die Bandbreite \mathbf{H} spielt aufgrund der variablen Stützstellen eine vernachlässigbare Rolle und kann deshalb auf eine Einheitsmatrix $\mathbf{H} = \mathbf{E}$ vereinheitlicht werden.

Die UKR-Regression-Funktion $f(\cdot)$ kann in Matrixschreibweise wie folgt formuliert werden

$$b_i(\bar{\mathbf{x}}; \bar{\mathbf{X}}) = \frac{K(\bar{\mathbf{x}} - \bar{\mathbf{x}}_i)}{\sum_j K(\bar{\mathbf{x}} - \bar{\mathbf{x}}_j)} \quad (5.13)$$

$$\bar{\mathbf{y}} = f(\bar{\mathbf{x}}; \bar{\mathbf{X}}) = \sum_{\hat{i}=1}^M \bar{\mathbf{y}}_{\hat{i}} b_{\hat{i}}(\bar{\mathbf{x}}; \bar{\mathbf{X}}) = \bar{\mathbf{Y}} \mathbf{b}(\bar{\mathbf{x}}; \bar{\mathbf{X}}),$$

wobei $\mathbf{b}(\bar{\mathbf{x}}; \bar{\mathbf{X}}) = (b_1(\bar{\mathbf{x}}; \bar{\mathbf{X}}), b_2(\bar{\mathbf{x}}; \bar{\mathbf{X}}), \dots, b_M(\bar{\mathbf{x}}; \bar{\mathbf{X}}))^T \in \mathbb{R}^M$ - ein Vektor aus Basisfunktionen - eine Parametrierung der Kernel-Funktionen im latenten Raum darstellt.

Das Optimieren einer UKR-Mannigfaltigkeit, oder die Adaption der latenten Stützstellen $\bar{\mathbf{X}}$, basiert auf der Minimierung des Rekonstruktionsfehlers über den Gradientenabstieg [57]

$$R(\bar{\mathbf{X}}) = \frac{1}{M} \sum_{\hat{i}} \|\bar{\mathbf{y}}_{\hat{i}} - f(\bar{\mathbf{x}}_{\hat{i}}; \bar{\mathbf{X}})\|^2 = \frac{1}{M} \|\bar{\mathbf{Y}} - \bar{\mathbf{Y}} \mathbf{B}(\bar{\mathbf{X}})\|_F^2, \quad (5.14)$$

wobei $\|\cdot\|_F$ eine Frobeniusnorm [28] ist und $\mathbf{B}(\bar{\mathbf{X}}) = (\mathbf{b}(\bar{\mathbf{x}}_1; \bar{\mathbf{X}}), \mathbf{b}(\bar{\mathbf{x}}_2; \bar{\mathbf{X}}), \dots, \mathbf{b}(\bar{\mathbf{x}}_M; \bar{\mathbf{X}}))$ eine Matrix aus Basisvektoren.

Um die triviale Minimierungslösung $R(\bar{\mathbf{X}}) = 0$, in der sich die Stützstellen $\bar{\mathbf{x}}_i$ ins Unendliche voneinander weg entfernen, kann eine Regularisierungsmethode hinzugefügt werden. Eine dieser Regularisierungen ist die *Leave-One-Out-Kreuzvalidierung* (LOOKV), bei der jedes Datenbeispiel $\bar{\mathbf{y}}_i$ von der Regressionsfunktion rekonstruiert werden soll, ohne es selbst zu benutzen. Um die Fehlerfunktion (5.14) in eine Leave-One-Out-Kreuzvalidierung umzuformen, erfordert es das Setzen der Diagonalelemente der Matrix $\mathbf{B}(\bar{\mathbf{X}})$ auf 0 und anschließend eine Normalisierung der Spalten auf die Summe 1.

Es ist bekannt, dass ein Gradientenabstieg in "seichten" lokalen Minima stecken bleiben kann. Deshalb ist eine Initialisierung der latenten Stützstellen im Bereich der tiefen Minima notwendig. Es gibt mehrere Möglichkeiten die Verteilung der latenten Stützstellen zu initialisieren, deren Einsatz von einer Datenverteilung abhängt. Dazu gehören PCA [39], Isomap [79] or Local Linear Embedding (LLE) [65]. Diese Methoden sind selbst in der Lage niedrigdimensionale Strukturen in Datenmengen zu erfassen. Jedoch ist PCA reduziert auf lineare Strukturen und Isomap und LLE bieten keine glatte Abbildung im Beobachtungsraum.

5.4.2 Leave-One-Out-Kreuzvalidierung

Bei der Regression wird eine beobachtete Datenmenge über eine angenommene Regressionsfunktion beschrieben. Die Parameter der Regressionsfunktion werden mittels einer Optimierung so geschätzt, dass der Verlauf der Regressionsfunktion durch die Daten verläuft. Angenommen, es gibt einen funktionalen Zusammenhang in den beobachteten Daten, so ist das Ziel der Regression diesen über eine Regressionsfunktion zu ermitteln. Die Güte der Regression kann über den Rekonstruktionsfehler aus Gleichung (5.14) ermittelt werden. Ein unerwünschter Effekt bei der Regression entsteht, wenn die Daten einerseits gut gefittet werden, aber andererseits der funktionale Zusammenhang nicht auf gewünschte Weise approximiert wird. Diesem, als Overfitting (siehe Abb. 5.6) bezeichneten Effekt, kann man mittels einer Minimierung des Leave-One-Out-Kreuzvalidierungsfehlers entgegenwirken. Die Leave-One-Out-Kreuzvalidierung [45] steht für die Auswertung des Rekonstruktionsfehlers für jedes beobachtete Datum $\bar{\mathbf{y}}_i$ ohne es selbst bei der Regression verwendet zu haben. Der entsprechende Kreuzvalidierungsfehler

$$R_{cv}(\bar{\mathbf{X}}) = \frac{1}{M} \sum_i \|\bar{\mathbf{y}}_i - f_{-\hat{i}}(\bar{\mathbf{x}}_i; \bar{\mathbf{X}})\|^2 = \frac{1}{M} \|\bar{\mathbf{Y}} - \bar{\mathbf{Y}}\mathbf{B}_{cv}(\bar{\mathbf{X}})\|_F^2 \quad (5.15)$$

mit dem ausgeschlossenen Datum \hat{i} in der Zielfunktion

$$f_{-\hat{i}}(\bar{\mathbf{x}}) = \sum_{\hat{i} \neq i} \bar{\mathbf{y}}_i \frac{K(\bar{\mathbf{x}} - \bar{\mathbf{x}}_{\hat{i}})}{\sum_{\hat{i} \neq j} K(\bar{\mathbf{x}} - \bar{\mathbf{x}}_j)}. \quad (5.16)$$




Abbildung 5.6: Beim Overfitting ist die Regression überangepasst an den Datensatz (links). Rechts im Bild ist der gewünschte glatte Verlauf der Regressionsfunktion.

Bei der Berechnung der Matrix \mathbf{B}_{cv} werden für die Kreuzvalidierung die Diagonalelemente auf null gesetzt, bevor die Spalten auf 1 normiert werden. Der Kreuzvalidierungsfehler lässt sich in Termen des Rekonstruktionsfehlers umformen

$$R_{cv}(\bar{\mathbf{X}}) = \frac{1}{M} \sum_{\hat{i}} \hat{S}_{\hat{i}}^2(\bar{\mathbf{X}}) \|\bar{\mathbf{y}}_{\hat{i}} - \bar{\mathbf{y}}(\bar{\mathbf{x}}_{\hat{i}}; \bar{\mathbf{X}})\|^2, \quad (5.17)$$

wobei $\hat{S}_{\hat{i}}^2$ den quadratischen Bestrafungsterm darstellt

$$\hat{S}_{\hat{i}}(\bar{\mathbf{X}}) = \frac{\sum_{\hat{j}} K(\bar{\mathbf{x}}_{\hat{i}} - \bar{\mathbf{x}}_{\hat{j}})}{\sum_{\hat{j} \neq \hat{i}} K(\bar{\mathbf{x}}_{\hat{i}} - \bar{\mathbf{x}}_{\hat{j}})}. \quad (5.18)$$

Die Herleitung der Gleichung (5.17) ist in der Arbeit von Klanke [44] aufgeführt. Die einfache Umsetzung dieser Kreuzvalidierung ohne zusätzlichen Rechenaufwand ist die Stärke des UKR-Ansatzes.

5.4.3 Spektrale Initialisierung

Eine spektrale Methode soll zur Initialisierung der latenten Variablen $\bar{\mathbf{X}}$ verwendet werden. Das Resultat $\hat{\mathbf{X}}$ einer spektralen Methode muss die bedingte UKR-Funktion mit Bandbreite auf $\bar{\mathbf{X}}$ skalieren. Die Optimierung des Modells erfolgt über Leave-One-Out-Kreuzvalidierung

$$\bar{\mathbf{X}}_{init} = \text{diag}(\mathbf{a}_{opt}) \hat{\mathbf{X}}, \text{ mit } \mathbf{a}_{opt} = \underset{\mathbf{a}}{\text{argmin}} R_{cv}(\text{diag}(\mathbf{a}) \hat{\mathbf{X}}). \quad (5.19)$$

Die Optimierung des LOOKV-Fehlers erfolgt bezüglich des q -dimensionalen Skalierungsvektors \mathbf{a} . Als Minimierungstechnik wird die Coarse-Grid-Suche verwendet. Der

entsprechende Gradient bezüglich des Skalierungsvektors ist

$$\nabla_{\mathbf{a}} R_{\text{cv}} \left(\text{diag}(\mathbf{a}) \hat{\mathbf{X}} \right) = -\frac{2}{M} \mathbf{a} * \left[\left(\hat{\mathbf{X}} * \hat{\mathbf{X}} \right) \left(\mathbf{Q} + \text{diag}(\mathbf{E}^T \mathbf{Q}) \right) \mathbf{E} - 2 \left(\hat{\mathbf{X}} * \left(\hat{\mathbf{X}} \mathbf{Q} \right) \right) \mathbf{E} \right], \quad (5.20)$$

wobei \mathbf{E} die Einheitsmatrix ist und \mathbf{Q} eine $M \times M$ -Matrix, die sich zusammensetzt als

$$\mathbf{Q} = \mathbf{P} * \{ \mathbf{M} - \mathbf{E} \mathbf{E}^T [\mathbf{M} * \mathbf{B}] \} \quad (5.21)$$

mit

$$\mathbf{M} = \bar{\mathbf{Y}}^T (\bar{\mathbf{Y}} \mathbf{B} - \bar{\mathbf{Y}}), \quad (5.22)$$

wobei das Symbol $*$ für das Schur-Produkt steht, bei dem Matrizen elementweise multipliziert werden. Die Matrizen \mathbf{B} und \mathbf{P} müssen aus den skalierten latenten Variablen $\bar{\mathbf{X}} = \text{diag}(\mathbf{a}) \hat{\mathbf{X}}$ anstatt der nicht skalierten $\hat{\mathbf{X}}$ berechnet werden.

5.4.4 Homotopie-basierende Optimierung

Klanke hat gezeigt, dass die spektralen Methoden nicht immer die optimale Lösungsmenge von latenten Variablen liefern. Um sich dem Minimum zu nähern, schlägt er einen Optimierungsansatz durch die Ausnutzung der Homotopie vor. In der Original-Publikation von Meinicke 2005 [56] wird bei der homotopie-basierten Optimierung eine iterative Kreuzvalidierung des UKR-Modells über eine Dichteschwelle der latenten Variablen betrachtet. Dabei wird iterativ die latenten Variablen $\bar{\mathbf{X}}^{\tilde{m}}$ für eine absteigende Sequenz der Dichten $\eta_1 > \eta_2 > \dots > \eta_{\tilde{M}-1} > \eta_{\tilde{M}} = 0$ minimiert

$$\bar{\mathbf{X}}^{\tilde{m}} = \underset{\bar{\mathbf{x}}}{\text{argmin}} R_{\text{cv}}(\bar{\mathbf{X}}), \quad \forall_i p(\bar{\mathbf{x}}_i) \geq \eta_{\tilde{m}} K(\mathbf{0}), \quad \tilde{m} = 1, \dots, \tilde{M}, \quad (5.23)$$

Die Lösung des \tilde{m} -ten Optimierungsvorgangs mit der Dichte $\eta_{\tilde{m}}$ ist der Ausgangspunkt für die Optimierung mit der nachfolgenden Dichte $\eta_{\tilde{m}+1}$ und so weiter. Die letzte Dichte $\eta_{\tilde{M}} = 0$ sorgt dafür, dass eine Optimierung ausschließlich auf der Kreuzvalidierung ohne jegliche Dichtebedingung berechnet wird.

5.4.5 Definitionsbereich im latenten Raum

Die Mannigfaltigkeit hat einen Gültigkeitsbereich im latenten Raum $\bar{\mathbf{x}}$. Dieser Bereich wird begrenzt durch eine Dichteschwelle

$$\mathcal{X} = \{ \bar{\mathbf{x}} | p(\bar{\mathbf{x}}) \geq \eta K(\mathbf{0}) \}, \quad (5.24)$$

wobei die Dichteschwelle dafür Sorge tragen muss, dass alle Stützstellen $\bar{\mathbf{x}}_i$ innerhalb der Mannigfaltigkeit liegen

$$\eta = \frac{1}{K(\mathbf{0})} \min_i p(\bar{\mathbf{x}}_i; \bar{\mathbf{X}}). \quad (5.25)$$

Mit der Schwelle aus (5.25) ist es gesichert, dass alle latenten Stützstellen $\bar{\mathbf{x}}_i$ innerhalb \mathcal{X} liegen.

5.4.6 Zusammenfassung des UKR-Ansatzes

1. Initialisierung: Bestimme eine Menge von $N'+1$ Lösungskandidaten $\hat{\mathbf{X}}_{init}^{n'}$, mit $n' = 1, \dots, N'+1$, nichtlinearen Spektralmethoden für unterschiedliche Parametersätze der Nachbarbeziehung und eine PCA-Lösung (Hauptkomponentenanalyse).
2. Skalierung: Finde die optimalen Skalierungsfaktoren $\mathbf{a}_{opt}^{n'}$ bezüglich des Kreuzvalidierungsfehlers

$$\mathbf{a}_{opt}^{n'} = \underset{\mathbf{a}}{\operatorname{argmin}} R_{cv}(\operatorname{diag}(\mathbf{a}) \hat{\mathbf{X}}^{n'}) \quad (5.26)$$

und skaliere jeden Lösungskandidaten $\hat{\mathbf{X}}^{n'}$ mit gefundenen Skalierungsfaktoren $\mathbf{a}_{opt}^{n'}$ zu einem Optimum $\bar{\mathbf{X}}_{init}^{n'} = \operatorname{diag}(\mathbf{a}_{opt}^{n'}) \hat{\mathbf{X}}^{n'}$ (siehe Gl. (5.19)).

3. Bester Lösungskandidat: Bestimme den Lösungskandidaten $\bar{\mathbf{X}}_{init} = \bar{\mathbf{X}}_{init}^{best}$ mit dem kleinsten Kreuzvalidierungsfehler

$$best = \underset{n'}{\operatorname{argmin}} R_{cv}(\bar{\mathbf{X}}_{init}^{n'}). \quad (5.27)$$

4. Homotopie-Optimierung: Resultiert der optimale Lösungskandidat aus einer skalierten PCA-Lösung, dann wird die Homotopie-Methode angewendet. Optimierte iterativ in \tilde{M} -Schritten mit absteigenden Dichteschwellen $\eta_1 > \eta_2 > \dots > \eta_{\tilde{M}} = 0$ den Kreuzvalidierungsfehler bezüglich der latenten Variablen $\bar{\mathbf{X}}$

$$\bar{\mathbf{X}}^{\tilde{m}} = \underset{\bar{\mathbf{X}}}{\operatorname{argmin}} R_{cv}(\bar{\mathbf{X}}), \quad \forall_i p(\bar{\mathbf{x}}_i) \geq \eta_{\tilde{m}} K(\mathbf{0}), \quad \tilde{m} = 1, \dots, \tilde{M} \quad (5.28)$$

Der letzte resultierende Satz von latenten Variablen ist $\bar{\mathbf{X}}^{\tilde{M}}$.

5. Minimierung des Kreuzvalidierungsfehlers: Resultiert der optimale Lösungskandidat aus einem nichtlinearen Modell einer Mannigfaltigkeit, z.B. Isomap oder LLE, dann wird angenommen, dass der Lösungskandidat nah an der optimalen Mannigfaltigkeit liegt. Daher wird der Lösungskandidat direkt bezüglich des Kreuzvalidierungsfehlers minimiert

$$\bar{\mathbf{X}}_{final} = \underset{\bar{\mathbf{X}}}{\operatorname{argmin}} R_{cv}(\bar{\mathbf{X}}). \quad (5.29)$$

6. Dichteschwelle: Setze die Dichteschwelle für den unterstützten Bereich im latenten Raum auf

$$\eta = \frac{1}{K(\mathbf{0})} \min_i p(\bar{\mathbf{x}}_i; \bar{\mathbf{X}}). \quad (5.30)$$

5.4.7 Gradientenabstieg und RPROP

Eine Minimierung des Kreuzvalidierungsfehlers (5.23) über den Gradientenabstieg [57] entspricht einem Lernprozess. Die Wahl einer Lernrate ist entscheidend für die notwendige Zeit bis zur Konvergenz gegen ein Minimum. Es gibt zwei gegensätzliche Anforderungen an eine Lernrate. In “seichten“ Bereichen des Fehlers im Parameterraum erfordert eine kleine Lernrate übermäßig viele Schritte bis zur Konvergenz. Andererseits führt eine zu groß gewählte Lernrate zu unerwünschten Oszillationen im Tal eines lokalen Minimums. Die Lösung ist eine adaptive Lernrate. Der RPROP-Algorithmus [62] (resilient backpropagation) verwendet eine Heuristik für die Lernrate in Form eines Updatewertes, bei der die lokale Topographie der Fehlerfunktion betrachtet wird.

Eine Manhattan-Lernregel mit einer individuellen Änderung jeder latenten Stützstelle $\bar{\mathbf{x}}_i$ mit dazugehörigen Updatewert Δ_i entspricht einem Gradientenabstieg

$$\Delta \bar{\mathbf{x}}_i(s) = \begin{cases} -\Delta_i & \frac{\partial R_{cv}}{\partial \bar{\mathbf{x}}_i} > 0 \\ +\Delta_i & \frac{\partial R_{cv}}{\partial \bar{\mathbf{x}}_i} < 0 \\ 0 & , \text{sonst.} \end{cases} \quad (5.31)$$

Jede latenten Stützstelle $\bar{\mathbf{x}}_i$ verfügt über einen eigenen Updatewert Δ_i . Dieser passt sich während des Lernprozesses der “Richtung“ der Fehlerfunktion R_{cv} an. Die Änderung des Updatewertes beschreibt die Fallunterscheidung

$$\Delta_i(s) = \begin{cases} \Delta_i(s-1) \eta^+ & \frac{\partial R_{cv}}{\partial \bar{\mathbf{x}}_i}(s-1) \frac{\partial R_{cv}}{\partial \bar{\mathbf{x}}_i}(s) > 0 \\ \Delta_i(s-1) \eta^- & \frac{\partial R_{cv}}{\partial \bar{\mathbf{x}}_i}(s-1) \frac{\partial R_{cv}}{\partial \bar{\mathbf{x}}_i}(s) < 0 \\ \Delta_i(s-1) & , \text{sonst} \end{cases} \quad (5.32)$$

mit Skalierungsfaktoren $0 < \eta^- < 1 < \eta^+$. Die Wahl des Skalierungsfaktors hängt von den Vorzeichen der zwei nachfolgenden Partialableitungen des Fehlers ab. Jede Änderung des Vorzeichens bedeutet einen Sprung über ein lokales Minimum. Die Ursache dafür ist ein zu großer Updatewert Δ_i und deshalb wird dieser im nächsten Schritt um den Faktor $\eta^- < 1$ verkleinert. Wenn die Vorzeichen gleich bleiben, dann wird der Updatewert um $\eta^+ > 1$ vergrößert, was zu einer Beschleunigung der Konvergenz führt.

Zusätzlich zu der Updateregeln (5.31) wird der Lernprozess beim Vorzeichenwechsel

wiederholt, d.h. der letzte Lernschritt wird rückgängig gemacht

$$\Delta \bar{\mathbf{x}}_i(s) = -\Delta \bar{\mathbf{x}}_i(s-1), \text{ wenn } \frac{\partial R_{cv}}{\partial \bar{\mathbf{x}}_i}(s-1) \frac{\partial R_{cv}}{\partial \bar{\mathbf{x}}_i}(s) < 0. \quad (5.33)$$

Das entspricht $\frac{\partial R_{cv}}{\partial \bar{\mathbf{x}}_i}(s-1) := 0$ in Gleichung (5.32). Der Lernprozess kann mit beliebigen Updatewerten Δ_0 initialisiert werden. Es gibt eine Beschränkung der Updatewerte durch eine Ober- und Untergrenze, um das Überlaufproblem der Float-Variablen bei Skalierung von (5.33) zu vermeiden.

5.5 Klassenspezifische Mannigfaltigkeiten

Die Idee hinter einer klassenspezifischen Mannigfaltigkeit ist die Erzeugung einer niedrigdimensionalen Repräsentation von Bewegungsmustern für jede Situationsklasse $\omega \in \Omega$ separat.

Eine zweidimensionale Mannigfaltigkeit, eingebettet in einem zwanzigdimensionalen Tschebyschow-Raum von Trajektorienpaaren, wird in Abb. 5.7 veranschaulicht. Diese Mannigfaltigkeit fungiert als eine Wissensbasis über die Situationsklasse amerikanisches Abbiegen (LL). Eine klassenspezifische Mannigfaltigkeit liefert die Basis für die Bewegungsprognose im Abschnitt 5.6. Exemplarisch in Abb. 5.7 wurden die Bewegungsmuster in Form von Fahrschläuchen an unterschiedlichen Stellen der Mannigfaltigkeit hervorgehoben. Bei einer kombinatorischen Vielfalt von Trajektorienpaaren zweier Fahrzeuge ist eine zweidimensionale Mannigfaltigkeit wahrscheinlich in dem Tschebyschow-Raum extrem gefaltet. Dennoch lassen sich Muster in dem Verlauf der Mannigfaltigkeit beobachten. Die Manöver 1,8 links in der Abb. 5.7 haben bezüglich der Startsituation die größte Entfernung zueinander. Oben links im Bereich des Manövers Nr. 2 liegt das rote Fahrzeug näher zum Kreuzungsmittelpunkt als das blaue und rechts unten bei Manöver Nr. 9 genau anders herum. Oben rechts liegen die Manöver Nr. 4 und Nr. 5, bei denen beide Fahrzeuge relativ synchron am Kreuzungsmittelpunkt voreinander abbiegen. Die Dichte η der latenten Variablen nach (5.25) wird über Graustufen, angefangen ab $\eta \geq 0,01$, in Abb. 5.7 dargestellt. Je höher die Dichte, desto dunkler der Bereich. Zur Erzeugung dieser Mannigfaltigkeit wurden 200 Referenzmuster aus 27 Sequenzen der Situationsklasse amerikanisches Abbiegen extrahiert. Bei der Extraktion wurden im ersten Schritt alle Sequenzen, wie in Abb. 5.3b veranschaulicht, zerschnitten und anschließend mit dem Lloyd-Algorithmus aus Abschnitt 5.3 auf 200 Referenzmuster ausgedünnt.




Abbildung 5.7: Eine zweidimensionale Mannigfaltigkeit der Situationsklasse "amerikanisches Abbiegen" mit beispielhaften Samples der Trajektorienpaare für eine Bewegungsprognose.

5.6 Nächste-Nachbarn-Klassifikation

Das interagierende Verhalten zweier Fahrzeuge für eine Situationsklasse, z.B. amerikanisches Abbiegen, wird in Form einer Mannigfaltigkeit im Merkmalsraum der Tschebyschow-Koeffizienten dargestellt. Jeder Merkmalsvektor (siehe Abschnitt 5.2) beinhaltet die Tschebyschow-Koeffizienten zweier Positions-Trajektorien für eine Bewegungsprognose zweier Fahrzeuge \mathcal{A} und \mathcal{B} mit Interaktion.

Der Verlauf der x -Position des Fahrzeugs \mathcal{A} wird nach (5.5) aus dem Vektor der Koeffizienten $\mathbf{c}_{x,\mathcal{A}}$ eine Funktion $x_{\mathcal{A}}(t')$ von t' extrahiert. Die Dimension t' ist eine Skalierung der Zeit t nach (5.2) und hängt von dem Prognosehorizont ab. Analog lassen sich die restlichen Trajektorien $y_{\mathcal{A}}(t')$ der y -Position des Fahrzeugs \mathcal{A} und die Trajek-

torien $x_{\mathcal{B}}(t')$ und $y_{\mathcal{B}}(t')$ des Fahrzeugs \mathcal{B} auf die Sekundendimension zurück skalieren. Die Stelle $t'_0 = -1$ im Definitionsbereich $[-1,1]$ der Tschebyschow-Zerlegung definiert die Startsituation der Fahrzeuge, die für spätere Nächste-Nachbarn-Klassifikation verwendet wird. Der restliche Verlauf $t' \in (-1,1]$ der Referenztrajektorie fungiert als Bewegungsprognose mit Interaktion. Die kinematischen Größen zum Zeitpunkt t'_0 Geschwindigkeit $v(t'_0)$, Beschleunigung $a(t'_0)$, Gierwinkel $\psi(t'_0)$ und Gierrate $\dot{\psi}(t'_0)$ lassen sich aus den Positions-Trajektorien ableiten. Der Geschwindigkeitsvektor $\tilde{\mathbf{v}}(t')$ zum Zeitpunkt t' für eines der Fahrzeuge wird wie folgt berechnet

$$\tilde{\mathbf{v}}(t') = \left(\frac{dx(t')}{dt'}, \frac{dy(t')}{dt'} \right)^T. \quad (5.34)$$

Zum Berechnen einer eindeutigen Orientierung $\psi(t')$ des Fahrzeugs wird bei den Positionstrajektorien vorausgesetzt, dass ein Fahrzeug nicht rückwärts gefahren ist, d.h. $v(t') = \|\tilde{\mathbf{v}}(t')\| > 0$. Damit liegt die vordere Stoßstange des Fahrzeugs stets in Fahrtrichtung bzw. in der jeweiligen Bewegungsrichtung. Eine Ausnahme existiert im Falle eines Stillstands, d.h. Geschwindigkeit $\tilde{\mathbf{v}}(t') = \mathbf{0}$, hier kann die Orientierung $\psi(t')$ des Fahrzeugs nicht eindeutig berechnet werden. Ein Stillstand des Fahrzeugs entspricht einer Steigung der Positionstrajektorie von 0 bzw. $\tilde{\mathbf{v}}(t') = 0$. In diesem Fall kann die Orientierung des Fahrzeugs aus dem nächsten Nachbarpunkt auf der Positionstrajektorie mit Steigung $\neq 0$ genommen werden. Der Gierwinkel wird auf Basis des Geschwindigkeitsvektors $\tilde{\mathbf{v}}(t')$ ermittelt

$$\psi(t') := \text{sgn}(v_y(t')) \arccos\left(\frac{v_x(t')}{\|\tilde{\mathbf{v}}(t')\|}\right), \text{ für } \tilde{\mathbf{v}}(t') \neq \mathbf{0} \text{ und } v(t') > 0. \quad (5.35)$$

Analog zu der Berechnung eines Geschwindigkeitsvektors (5.34) wird der Beschleunigungsvektor über eine zweifache Ableitung aus dem Positionsverlauf berechnet. Die Richtung des Beschleunigungsvektors relativ zum Geschwindigkeitsvektor bestimmt das Vorzeichen und daher, ob es sich um eine Verzögerung oder eine Beschleunigung handelt. Die Gierrate $\dot{\psi}(t'_0)$ des Fahrzeugs wird über die zeitliche Ableitung des Gierwinkels an der Stelle t'_0 berechnet. Zusammengefasst bilden folgende Größen einen kinematischen Startzustand $\mathbf{s}(t'_0)$ eines Fahrzeugs aus einer Mustertrajektorie

$$\mathbf{s}(t'_0) = (x(t'_0), y(t'_0), v(t'_0), a(t'_0), \psi(t'_0), \dot{\psi}(t'_0)). \quad (5.36)$$

Die Startzustände $\mathbf{s}_{\mathcal{A}}^{(\kappa)}(t'_0)$ und $\mathbf{s}_{\mathcal{B}}^{(\kappa)}(t'_0)$ aus einem Trajektorienpaar (κ) beschreiben eine Situation zwischen zwei Fahrzeugen auf einer Kreuzung. Die Situationserkennung für ein beobachtetes Zustandspaar $\mathbf{s}_{\mathcal{A}}^{obs}$ und $\mathbf{s}_{\mathcal{B}}^{obs}$ entspricht einem Suchprozess auf Mannigfaltigkeiten nach ähnlichen Startzuständen der Trajektorienpaare. Für den Vergleich von Zustandsvektoren, die über Elemente unterschiedlicher Dimensionen verfügen, wird die Mahalanobis-Distanz [53] benutzt. Dabei leisten die Dimensionen mit einer größeren Varianz einen kleineren Beitrag zu der Distanz als die Dimensionen mit kleinerer Varianz. Die Distanz zwischen zwei Kreuzungssituationen erfolgt über

die Summe zweier Mahalanobis-Distanzen

$$\begin{aligned} dist_{A,B}^{(\kappa)} &= dist_A^{(\kappa)} + dist_B^{(\kappa)} \\ &= \sqrt{\left(\mathbf{s}_A^{(\kappa)}(t'_0) - \mathbf{s}_A^{obs}\right)^T Cov^{-1} \left(\mathbf{s}_A^{(\kappa)}(t'_0) - \mathbf{s}_A^{obs}\right)} \\ &\quad + \sqrt{\left(\mathbf{s}_B^{(\kappa)}(t'_0) - \mathbf{s}_B^{obs}\right)^T Cov^{-1} \left(\mathbf{s}_B^{(\kappa)}(t'_0) - \mathbf{s}_B^{obs}\right)}, \end{aligned} \quad (5.37)$$

wobei Cov die Kovarianzmatrix ist. Die Kovarianzmatrix Cov wird aus einem Satz von Trainingsdaten \mathbf{s}_{train} wie folgt ermittelt

$$Cov = Var(\mathbf{s}_{train}) = E\{(\mathbf{s}_{train} - E(\mathbf{s}_{train}))^2\}, \quad (5.38)$$

wobei E der Erwartungswert ist.

Aufgrund einer Vielzahl von lokalen Distanz-Minima (5.37) der Kreuzungssituationen innerhalb einer Topologie der Mannigfaltigkeit sind Optimierungsverfahren wie z.B. Gradientenabstieg [69] nicht von Vorteil.

Sie finden im besten Fall ein lokales Minimum bzw. einen nächsten Nachbar. Daher wird hier eine gitterbasierte Suche

(siehe Abb. 5.8) nach den k -nächsten-Nachbarn durchgeführt. Die Knoten des Gitters bilden die Samples. Die Samples werden in erster Linie dahingehend überprüft, ob sie innerhalb des Definitionsbereichs bzw. über einer Dichteschwelle η der Mannigfaltigkeit liegen (siehe Abschnitt 5.4.5). Liegt das Sample oberhalb der Dichteschwelle, dann erfolgt die Extraktion der Startsituation (5.36), die durch die beiden Fahrzeugzustände definiert ist. Ein Ähnlichkeitsgrad nach (5.37) zu der beobachteten Situation wird bestimmt.




Abbildung 5.8: Die Suche auf einem aufgespannten Gitter, das über eine Mannigfaltigkeit aufgespannt ist.

Insgesamt werden k -nächste-Nachbarn $\kappa_1, \kappa_2, \dots, \kappa_k$ auf allen Mannigfaltigkeiten be-

stimmt

$$\begin{aligned}
\kappa_1 &= \min_{\kappa \in K} \left(dist_{\mathcal{A}, \mathcal{B}}^{(\kappa)} \right) \\
\kappa_2 &= \min_{\kappa \in K \setminus \{\kappa_1\}} \left(dist_{\mathcal{A}, \mathcal{B}}^{(\kappa)} \right) \\
\kappa_3 &= \min_{\kappa \in K \setminus \{\kappa_1, \kappa_2\}} \left(dist_{\mathcal{A}, \mathcal{B}}^{(\kappa)} \right) \\
&\dots \\
\kappa_k &= \min_{\kappa \in K \setminus \{\kappa_1, \dots, \kappa_{k-1}\}} \left(dist_{\mathcal{A}, \mathcal{B}}^{(\kappa)} \right).
\end{aligned} \tag{5.39}$$

Die k -nächsten-Nachbarn besitzen die kleinsten Distanzen gemäß des Distanzmaßes (5.37) aus der gesamten Sample-Menge K . Die Auflösung des Gitters und die Anzahl der nächsten Nachbarn gilt es empirisch zu bestimmen, da diese einen Einfluss auf das Klassifikationsergebnis haben.

Jeder der k -nächsten-Nachbarn $\kappa_1, \dots, \kappa_k$ entstammt aus einer Klasse $\omega \in \Omega$ von interagierenden Bewegungsmustern, die jeweils durch eine Mannigfaltigkeit repräsentiert werden. Die Klasse eines nächsten Nachbarn wird zur Bestimmung einer Klassenzugehörigkeitswahrscheinlichkeit verwendet. Die Anzahl der k -nächsten-Nachbarn, die zu der Klasse ω gehören, wird als k_ω notiert. Die Klassenzugehörigkeitswahrscheinlichkeit für eine Situationsklasse ω kann wie folgt berechnet werden

$$P(\omega) = k_\omega / k. \tag{5.40}$$

Über eine Rückweisungsklasse können Situationen abgefangen werden, die nicht mit den Mannigfaltigkeiten klassifizierbar sind. Dazu wird eine maximale Fehlerschwelle eingeführt. Das Überschreiten der Fehlergrenze bedeutet, dass die Situationen keinen Mindestähnlichkeitswert aufweisen, um als ähnliche Situation erkannt zu werden.

5.7 Evaluation

Zur Erzeugung der klassenspezifischen Mannigfaltigkeiten wurde die UKR-Toolbox Version 2b vom 05.04.2007 von Stefan Klanke ¹ verwendet. Im Rahmen der Evaluation soll untersucht werden, in wieweit sich die Repräsentation von interagierenden Manövern zweier Fahrzeuge durch Mannigfaltigkeiten als eine Wissensrepräsentation für die Situationserkennung und Bewegungsprognose eignet. Eine Mannigfaltigkeiten repräsentieren ausschließlich Manöver einer bestimmten Klasse. Zum Trainieren einer Mannigfaltigkeit wird die Unsupervised Kernel Regression verwendet. In der Testphase wurde eine Reihe von Kreuzungssequenzen iterativ über die k -nächsten-Nachbarn

¹ <http://www.sklanke.de/>

(5.40) klassifiziert. Auf Basis der Klassifikation werden die Bewegungsmuster aus der Mannigfaltigkeit extrahiert und als Bewegungsprognose auf Genauigkeit bewertet.

In der Abb. 3.10 werden 6 Situationsklassen zwischen zwei Fahrzeugen auf einer vierarmigen Kreuzung präsentiert. Die Situationsklassen werden entsprechend den beabsichtigten Überquerungsrichtungen (L - links abbiegen, R - rechts abbiegen, G - geradeaus durchfahren) der Fahrzeuge definiert. Ausgeschlossen sind dabei Situationen, in denen einer der Fahrer wendet.

Die Trainingsphase besteht aus einer Regression von interagierenden Bewegungsmustern der 6 Situationsklassen und wird durch folgende Schritte zusammengefasst:

1. Zerlegung der 97 Kreuzungssequenzen in 2,52 s lange Trajektorienpaare (siehe Abb. 5.3b)
2. Approximation der Trajektorienpaare über Tschebyschow-Polynome der Ordnung 7 (siehe Abb. 5.4)
3. Aufteilung der Trajektorienpaare in 6 mögliche Situationsklassen {LL, LG, LR, GG, RR, GR}
4. Ausdünnung der Trajektorienpaare bzw. Merkmalsvektoren auf 250 Trajektorien mit Hilfe des Lloyd-Algorithmus für jede Situationsklasse individuell
5. Nichtlineare Regression über die Unsupervised Kernel Regression mit 15000 Trainingsschritten mit der Homotopie-basierenden Optimierung mit der Dichtefolge von $\eta_{\bar{m}} \in (0,2; 0,1; 0,05; 0,02; 0,01)$ auf Koeffizientenvektoren aus der Tschebyschowapproximation

Nach dem Prinzip der Leave-One-Out-Kreuzvalidierung wird für das Training die Sequenz ausgeschlossen, die in der Testphase evaluiert werden soll. Damit soll die Evaluation ausschließlich auf der Wissensbasis aus anderen Trajektorien vollzogen und somit die Generalisierungsfähigkeit des Klassifikators validiert werden.

In der Tabelle 5.1 wird der mittlere Rekonstruktionsfehler nach Gl. (5.14) für 97 Kreuzungsszenarien zwischen zwei Fahrzeugen, die bereits im Abschnitt 3.6 als eine hochgenaue SimCity-Messreihe vorgestellt wurde, dargestellt. Hinter dem Kürzel der Situationsklasse steht die Anzahl der ausgewerteten Testsequenzen.

Tabelle 5.1: Klassenspezifischer Rekonstruktionsfehler für alle Testsequenzen.

	LL (27)	LG (24)	LR (15)	GG (9)	RR (8)	GR (14)
$R(\bar{\mathbf{X}})$	$1,93 \pm 0,64$	$0,53 \pm 0,28$	$1,56 \pm 0,44$	$2,23 \pm 0,32$	$0,20 \pm 0,06$	$0,40 \pm 0,24$

Das Erhöhen der Anzahl der Lernschritte und die Reduktion der Dichte η auf 0 verringert den Rekonstruktionsfehler $R(\bar{\mathbf{X}})$, hätte jedoch den Effekt des Overfitting

bzw. des Auswendiglernens zur Folge. Deshalb lag unsere empirisch bestimmte Grenze für die Dichte η bei 0,1. Die Situationsklassifikation basiert auf der Klassenzugehörigkeitswahrscheinlichkeit der $k = 5$ nächsten Nachbarn nach (5.40). Für eine Beispielsequenz, in der beide Fahrzeuge voreinander nach links abbiegen, wird in Abb. 5.9 der Klassifikationsverlauf veranschaulicht. Die Wahrscheinlichkeitsverläufe der 6 Situationsklassen (LL,LR,RR,LG,GG,GR) haben zu Beginn der Sequenz mehrere Sprünge von der Klasse LL auf LG und dann auf LR, bis die Situation ab der gestrichelten vertikalen Linie bis zum Ende der Sequenz richtig klassifiziert wird. Der Erkennungszeitpunkt der richtigen Situationsklasse liegt dann vor, sobald die Wahrscheinlichkeit der wahren Situationsklasse die 50-Prozent-Marke überschreitet und diese kontinuierlich bis zum Ende der Sequenz beibehält. Bei einer Klassenzugehörigkeitswahrscheinlichkeit von $P(\text{LL}) = 1$ haben alle 5 nächste Nachbarn den Ursprung auf der Mannigfaltigkeit der Situationsklasse mit dem Label LL.

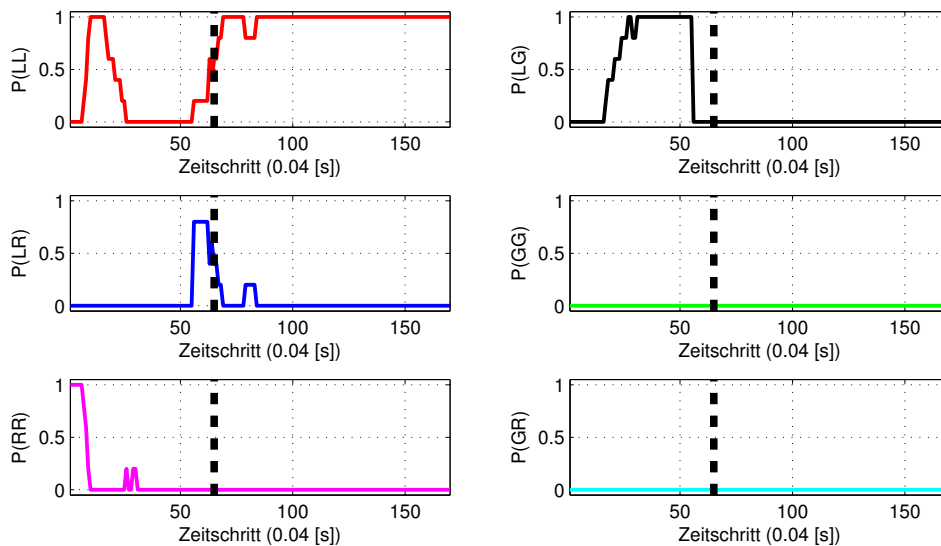


Abbildung 5.9: Klassenzugehörigkeitswahrscheinlichkeit für die sechs Situationsklassen (LL,LR,RR,LG,GG,GR) mit dem frühesten Erkennungszeitpunkt (gestrichelte Linie) der wahren Situationsklasse LL.

Eine mögliche Ursache für die Unsicherheit in der Klassifikation am Anfang der Sequenz liegt in der großen Entfernung der Fahrzeuge zur Kreuzung. In dieser frühen Phase des Zufahrens auf eine Kreuzung überlappen sich die Merkmale bzw. die Fahrzeugzustände mehrerer Situationsklassen, d.h. in vielen Situationsklassen führen die beiden Fahrzeuge ähnlich auf eine Kreuzung zu.

Aus der Vogelperspektive veranschaulicht die Abbildung 5.10 die Situation zum Erkennungszeitpunkt. Es ist erkennbar, dass beide Fahrzeuge zum Erkennungszeitpunkt genügend Abstand voneinander und zu der Kreuzung haben. Es wurde eine Refe-

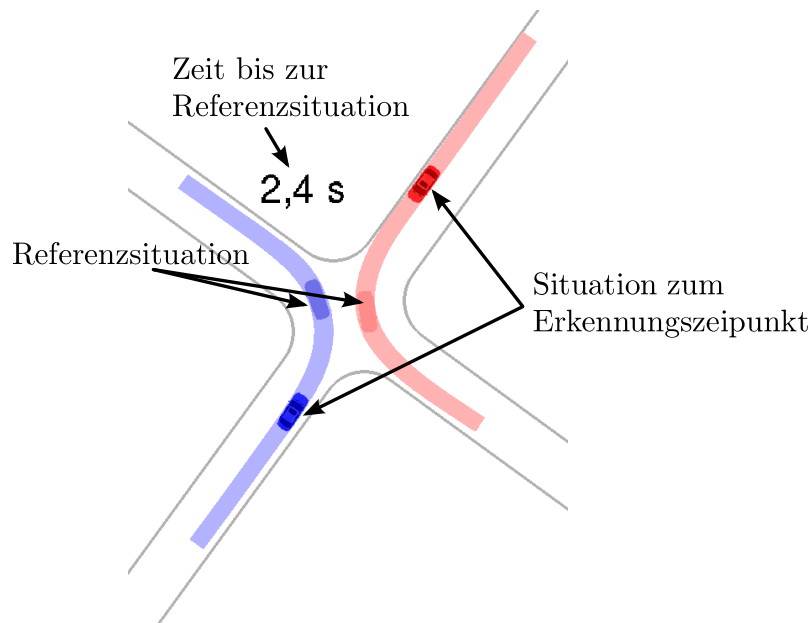


Abbildung 5.10: Bewertung des Erkennungszeitpunktes relativ zu einer Referenzsituation. Die Referenzsituation ist definiert, an der das letzte Fahrzeug den zum Kreuzungsmittelpunkt nächst gelegenen Punkt erreicht hat.

renzsituation definiert, in der beide Fahrzeuge den Kreuzungsmittelpunkt passiert haben. Die vergangene Zeit von der erkannten Situation bis zur Referenzsituation ist in Abb. 5.10 in Sekunden angegeben und ist in diesem Bsp. 2,4 s.

Für die SimCity-Messreihe (siehe Abschnitt 3.6) werden die Erkennungszeitpunkte aus der Situationsklassifikation in den Abb. 5.11, 5.12, 5.13 und 5.14 präsentiert. In allen Sequenzen wurde die richtige Situationsklasse erkannt. Anders als in den vorherigen Kapiteln soll hier der Erkennungszeitpunkt der richtigen Situationsklasse über die Fahrzeugkonstellation aus der Vogelperspektive veranschaulicht werden. Eine möglichst frühe Erkennung der Situationsklassen ist deutlich aus den Fahrzeugkonstellationen in den Abbildungen zu erkennen. Es ist zu beachten, dass bei manchen zusammengesetzten Manövern ein Fahrzeug später den Kreuzungsbereich anfährt und somit der Erkennungszeitpunkt für eine Situationsklasse sich zeitlich nach hinten aufschiebt. Dieses lässt sich besonders bei der Sequenz in Abb. 5.111 beobachten. Dabei ist das blaue Fahrzeug mitten im Abbiegeprozess, während das rote erst die Kreuzung anfährt. Der Erkennungszeitpunkt wird solange aufgeschoben, bis auch Merkmale bzw. Zustandsgrößen für das Abbiegen des roten Fahrzeugs sich von den anderen Situationsklassen differenzieren haben.

Der mittlere Erkennungszeitpunkt bis zur Referenzsituation liegt für die 97 Kreuzungssequenzen bei $3,5089 \pm 1,133$ s mit einem Minimum in der Sequenz 31 mit 1,28 s vor der Referenzsituation.

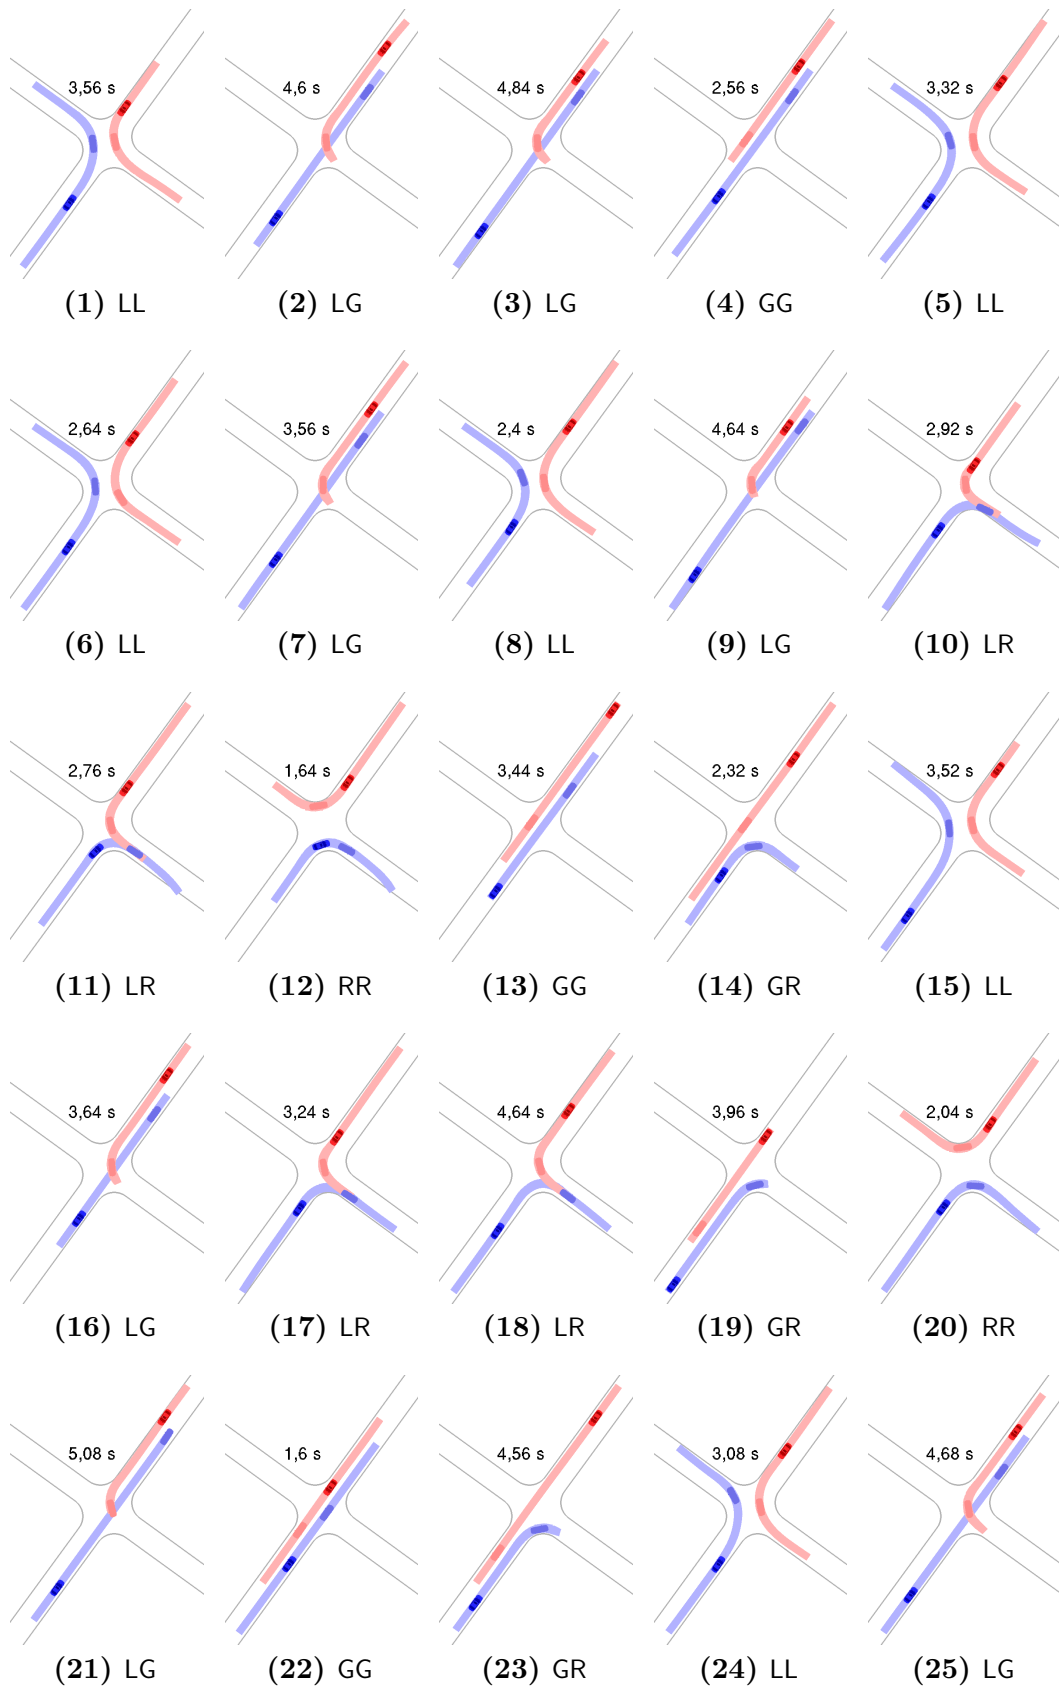


Abbildung 5.11: Ergebnisse der Situationsklassifikation für die ersten 25 Sequenzen in Form von eingezeichneten Fahrzeugpositionen zum Erkennungszeitpunkt. Zusätzlich gibt es eine relative Zeitangabe des Erkennungszeitpunkts zur Referenzsituation.

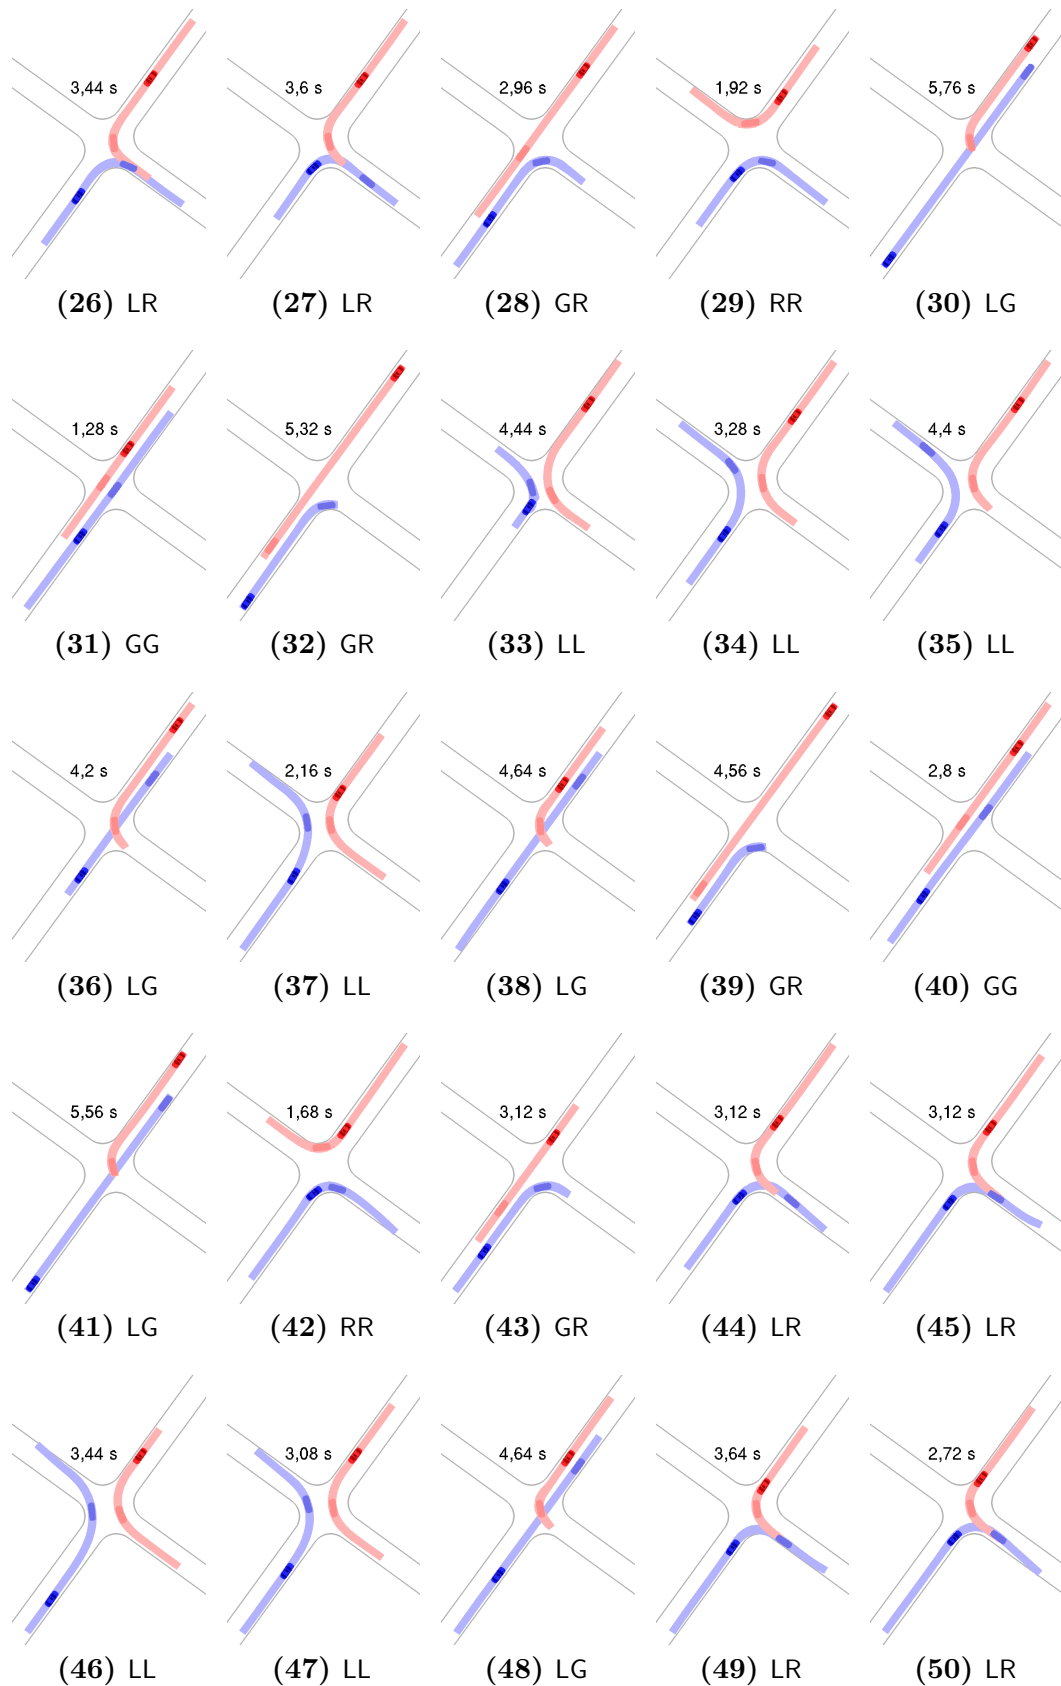


Abbildung 5.12: Ergebnisse der Situationsklassifikation für Sequenzen 26 bis 50 in Form von eingezeichneten Fahrzeugpositionen zum Erkennungszeitpunkt. Zusätzlich gibt es eine relative Zeitangabe des Erkennungszeitpunkts zur Referenzsituation.

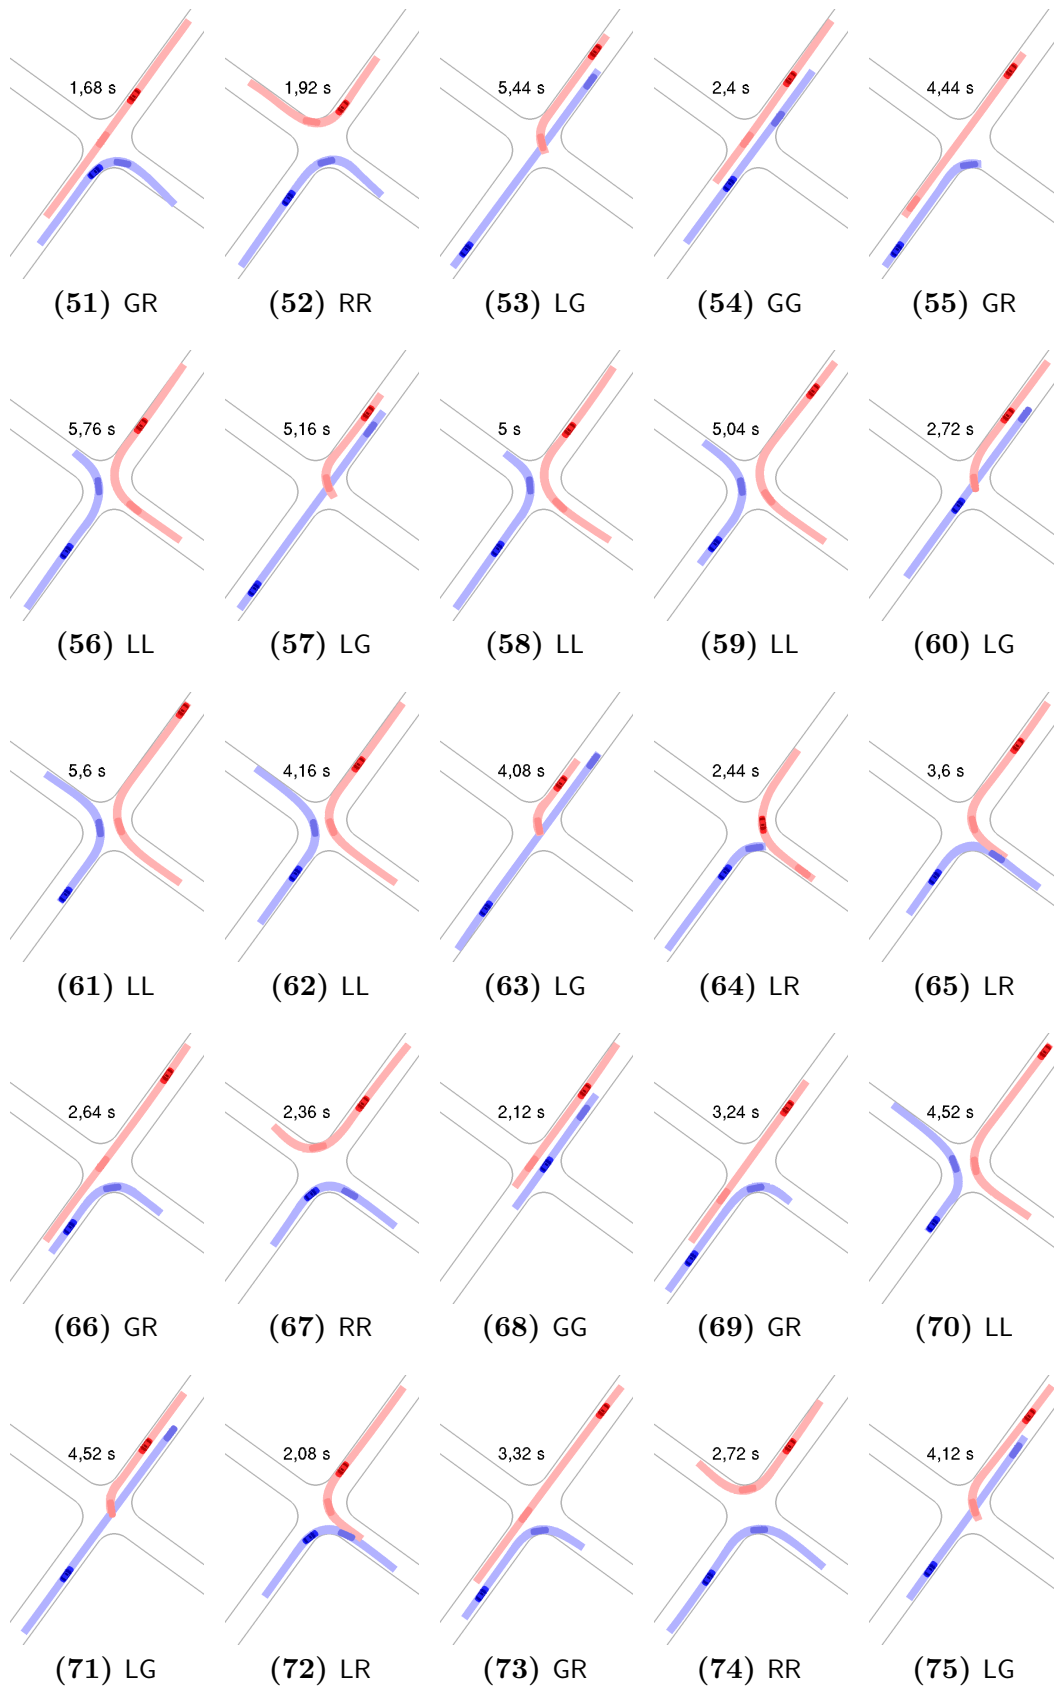


Abbildung 5.13: Ergebnisse der Situationsklassifikation für Sequenzen 51 bis 75 in Form von eingezeichneten Fahrzeugpositionen zum Erkennungszeitpunkt. Zusätzlich gibt es eine relative Zeitangabe des Erkennungszeitpunkts zur Referenzsituation.

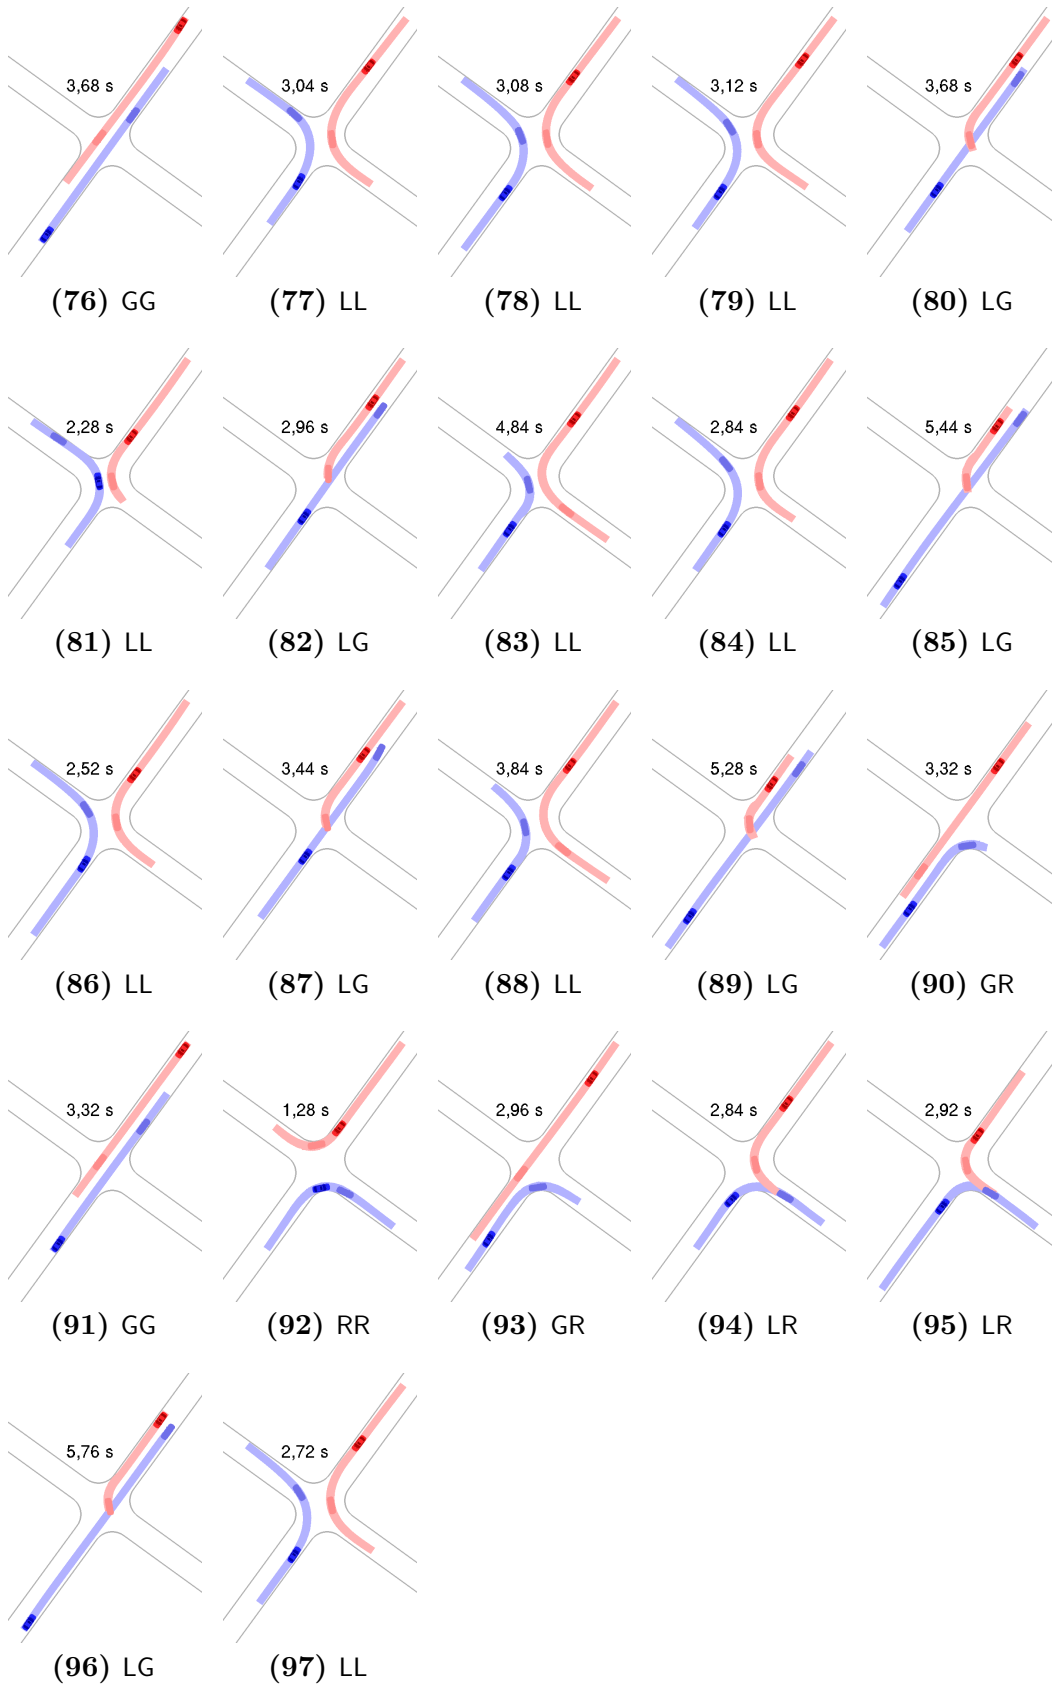


Abbildung 5.14: Ergebnisse der Situationsklassifikation für Sequenzen 76 bis 97 in Form von eingezeichneten Fahrzeugpositionen zum Erkennungszeitpunkt. Zusätzlich gibt es eine relative Zeitangabe des Erkennungszeitpunkts zur Referenzsituation.

5.7.1 Prognosegenauigkeit

In diesem Abschnitt soll die Prognosegenauigkeit auf Basis der Bewegungsmuster aus der Mannigfaltigkeit untersucht werden. Dabei werden die Bewegungsmuster des ersten Nachbars κ_1 aus (5.39) für die Prognose in Betracht gezogen. Deren Startsituation ist die ähnlichste zu der aktuell vorgegebenen. Diese Prognose soll mit der Bewegungsextrapolation gegen die Ground-Truth-Bewegung verglichen werden. Bei dieser Extrapolation werden die Längsbeschleunigung und die Gierrate als konstante Eingabegrößen mit dem Einspurmodell aufintegriert. Speziell wird für den Zeitpunkt von 2,52 s in der Zukunft der prognostizierte Fahrzeugzustand des nächsten Nachbars κ_1 und der Fahrzeugzustand aus der Extrapolation mit dem Ground-Truth-Zustand verglichen.

Tabelle 5.2 veranschaulicht für beide Prognoseformen den mittleren Fehler bezüglich Position, Geschwindigkeit, Beschleunigung, Gierwinkel und Gierrate mit Standardabweichungen. Die Testsequenzen sind bezüglich der Situationsklassen nicht gleichverteilt. Die am zahlreichsten sind die Situationsklassen LL und LG. Der Prognosefehler für 2,52 s ist im Vergleich zur Extrapolation bzgl. aller physikalischer Größen kleiner. Ähnlich zu der Situationsklasse LL ist bei LR deutlich der kleinere Fehler der Klassifikatorprognose im Vergleich zur Extrapolation zu sehen. Bei der Situationsklasse LG wurden bis auf die Position alle physikalischen Größen genauer vorhergesagt. Ein Nachteil bei der Integration einer Eingabegröße mit dem Einspurmodell sind die fehlenden Grenzen. Im Anwendungsfall bedeutet dies, eine kurze Beschleunigung eines Fahrzeugs wird über den gesamten Prognosehorizont vom Einspurmodell konstant aufintegriert. Im Gegensatz dazu sind die Bewegungsmuster aus der Mannigfaltigkeit auf die typischen Beschleunigungswerte beschränkt.

Bei den GG-Manövern liegt die Extrapolation bei der Positionsprognose deutlich vorne. Ein möglicher Grund dafür ist der zu kleine Trainingsdatensatz aus wenigen Sequenzen. Beim Manöver GR liegt die Prognosegenauigkeit bis auf den Positionsfehler des Klassifikators vorne. Bei der RR-Situationsklasse ist deutlich die Stärke der Mannigfaltigkeiten zu beobachten, die den Fehler deutlich geringer halten.

Tabelle 5.2: Vergleich des mittleren Fehlers und der Standardabweichung der prognostizierten Fahrzeugzustände nach 2,52 s zwischen (erste Zeile) der Bewegungsextrapolation und (zweite Zeile) dem nächsten Bewegungsmuster κ_1 nach (5.39) aus den klassenspezifischen Mannigfaltigkeiten.

Klasse	Position m	Geschw. m/s	Beschl. m/s ²	Gierwinkel rad	Gierrate rad/s
LL (27)	2,93 ± 1,50	1,99 ± 1,35	1,38 ± 1,07	0,43 ± 0,29	0,36 ± 0,20
	2,78 ± 2,42	0,95 ± 0,89	0,55 ± 0,52	0,25 ± 0,35	0,20 ± 0,27
LR (15)	3,14 ± 1,60	2,28 ± 1,23	1,62 ± 0,97	0,51 ± 0,40	0,38 ± 0,24
	2,16 ± 2,12	0,79 ± 0,93	0,56 ± 0,51	0,24 ± 0,40	0,20 ± 0,27
LG (24)	1,41 ± 1,25	1,37 ± 1,19	1,07 ± 1,04	0,14 ± 0,24	0,16 ± 0,23
	2,68 ± 2,55	1,11 ± 1,25	0,59 ± 0,62	0,10 ± 0,17	0,11 ± 0,16
GG (9)	0,47 ± 0,58	0,43 ± 0,65	0,36 ± 0,48	0,02 ± 0,02	0,01 ± 0,01
	4,39 ± 4,59	1,73 ± 1,87	0,60 ± 0,70	0,08 ± 0,18	0,12 ± 0,22
GR (14)	1,79 ± 1,70	1,35 ± 1,45	0,99 ± 1,05	0,27 ± 0,36	0,22 ± 0,26
	2,51 ± 2,29	0,96 ± 1,10	0,60 ± 0,57	0,08 ± 0,15	0,10 ± 0,14
RR (8)	3,74 ± 1,68	2,38 ± 1,44	1,69 ± 1,09	0,64 ± 0,38	0,43 ± 0,22
	2,31 ± 2,09	0,72 ± 0,81	0,56 ± 0,49	0,26 ± 0,45	0,26 ± 0,32

5.8 Zusammenfassung

In diesem Kapitel lag der Fokus auf dem Lernen von zusammengesetzten Bewegungsmustern an Kreuzungen zwischen zwei Fahrzeugen. Dazu wurden unterschiedliche Kreuzungssequenzen, die auf einer Testkreuzung mit mehreren Fahrern aufgezeichnet wurden, als Trainingsdaten herangezogen. Als Anforderung für die Bewegungsprognose wurde ein zeitlicher Horizont von hierbei 2,52 s festgelegt. Entsprechend dieses Prognosehorizontes wurden die aufgezeichneten Sequenzen inkrementell zerlegt. Danach erfolgte eine Kompression der Trajektorienabschnitte über eine Zerlegung in Tschebyschow-Polynome. Eine repräsentative Menge von Bewegungsmustern wurde mit Hilfe eines Cluster-Verfahrens ausgedünnt.

Mittels der Unsupervised-Kernel-Regression konnte für jede Situationsklasse eine zweidimensionale Mannigfaltigkeit im Raum der Tschebyschow-Koeffizienten trainiert werden. In der Testphase wurden die Mannigfaltigkeiten als Wissensbasis verwendet. Ein gemessener Zustand zweier Fahrzeuge in einer Kreuzungssituation lieferte die Eingabe für eine Nächste-Nachbarn-Suche auf den jeweiligen klassenspezifischen Mannigfaltigkeiten. Der Startzustand eines Trajektorienabschnitts, extrahiert aus der Mannigfaltigkeit, dient als Vergleichsmuster für den aktuell gemessenen Zustand.

Eine Leave-One-Out-Kreuzvalidierung auf 97 realen Kreuzungssequenzen bekräftigt eine zuverlässige Erkennung der Situation bevor die Fahrzeuge die Kreuzung passiert

haben. Dazu wurden die Erkennungszeitpunkte zur leichteren Interpretation aus der Vogelperspektive in den Abb. 5.11, 5.12, 5.13 und 5.14 dargestellt.

Zudem wurde die Genauigkeit der Bewegungsprognose mit einer Bewegungsextrapolation verglichen. Es konnte gezeigt werden, dass speziell bei den zusammengesetzten Abbiegemanövern die Prognose über die Mannigfaltigkeiten genauer bezüglich meiste kinematischen Zustände nach 2,52 s vorhergesagt werden konnte. Dabei ist die Vorhersage von Geradeausmanövern (G) jedoch schlechter als mit der Extrapolation. Die Vielfalt der Möglichkeiten an Zustandskonstellationen wurde demnach nicht hinreichend erfasst und könnte in einer aufbauenden Arbeit durch eine größere Trainingsmenge behoben werden.

Die Evaluation dieses Ansatzes wurde in Matlab®¹ und in Form einer Simulation durchgeführt. Die Implementierung hat bei einer nicht optimierten Version eine Performanz von 2 – 3 Sekunden pro Situation auf einem Standard-Rechner². Eine Implementierung des Ansatzes in der Programmiersprache C könnte die Performanz um den Faktor 100 steigern.

Eine Auswertung auf unterschiedlichen Kreuzungen im Realverkehr müsste als nächstes untersucht werden. Eine Erweiterung auf Interaktionen mit drei Fahrzeugen wäre denkbar, könnte jedoch an einer repräsentativen Stichprobe von möglichen Kreuzungssequenzen scheitern. Der Grund dafür ist der exponentielle Anstieg an möglichen Zustandskonstellationen mit einer zunehmenden Anzahl von Fahrzeugen.

1 <http://www.mathworks.de/>

2 Intel Core i7 mit 3,0 GHz, 4 GB RAM

Kapitel 6

Zusammenfassung

Das Autofahren in Zukunft soll durch intelligente Fahrerassistenzsysteme sicherer gemacht werden. Kein Fahrer ist vor Fehlern im Straßenverkehr vollkommen sicher. Manchmal reicht auch ein Sekundenbruchteil der Unaufmerksamkeit des Fahrers, um in eine kritische Situation zu geraten. Durch moderne Sensorik kann einem Fahrzeug die Fähigkeit verliehen werden, die Umwelt ähnlich dem Menschen wahrzunehmen. Andere Verkehrsteilnehmer können von den Onboard-Sensoren als Objekte mit einer Entfernung und Bewegungsrichtung geschätzt werden. Die Algorithmen der Situationsanalyse prognostizieren die Bewegung der Verkehrsteilnehmer. Mit einer Bewegungsprognose als Basis erfolgt eine Abschätzung der Gefahr in einer Situation. Je nach Gefahrenwahrscheinlichkeit kann der Fahrer visuell und akustisch gewarnt oder bei besonders kritischen Situationen bei der Unfallvermeidung kinästhetisch unterstützt werden.

Der Fokus dieser Arbeit liegt auf der Analyse von Kreuzungssituationen. Dazu gehören eine Bewegungsprognose, Gefahrenschätzung und Erkennung von Abbiegemanövern. Drei Ansätze zu unterschiedlichen Anforderungen wurden in dieser Arbeit vorgeschlagen und evaluiert. Im ersten Ansatz liegt der Fokus auf einer Gefahrenschätzung, in der zur Bewegungsprognose der gesamte Handlungsspielraum bei unkritischer Fahrweise eines durchschnittlichen Fahrers betrachtet wird. Durch die Betrachtung des gesamten Handlungsspielraumes soll die Unsicherheit bezüglich der jeweiligen Fahrerintention in vollem Umfang berücksichtigt werden. Über ein Modell eines elementaren Kreuzungsmanövers können beliebige Abbiegemanöver mit gekoppelter Verzögerung oder Beschleunigung erzeugt werden. Der Handlungsspielraum der Fahrer besteht ausschließlich aus elementaren Manövern, deren kinematische Grenzen denen des Alltagsverkehrs entsprechen. Bewusst werden extreme Manöver bei der Gefahrenschätzung außer Acht gelassen, weil sie bereits ein Indiz auf ein notwendiges Kollisionsvermeidungsmanöver sind. Die Essenz dieses Ansatzes ist, dass eine kritische Situation dann vorliegt, wenn beide Fahrer mit üblicher Fahrdynamik nicht mit sicherem Abstand aneinander vorbei fahren können und somit keinen gewöhnlichen Handlungsspielraum mehr haben.

Anhand des Handlungsspielraumes wird eine Gefahr geschätzt, die bei zwei aufeinander zufahrenden Fahrzeugen stets vorhanden ist. Eine Obergrenze für die Gefahr wurde empirisch auf einer Testreihe von Kreuzungssequenzen ermittelt. Diese Grenze bestimmt die Feel-Safe Zone, das Intervall auf der Gefahrenwahrscheinlichkeitsskala zwischen völlig ungefährlich bis hin zu dem empirisch ermitteltem akzeptablen Gefahrenmaximum. Die besondere Recheneffizienz ermöglicht den Einsatz dieses Ansatzes für Situationen mit zwei Fahrzeugen in einem Versuchsträger mit einer echtzeitfähigen Situationsbewertung innerhalb eines 20 ms Rechenzyklusses. Eine effiziente Erweiterung des Ansatzes auf Situationen mit mehreren Fahrzeugen wurde vorgeschlagen. Für die zukünftige Erweiterung dieses Ansatzes sollen komplexere Manöver auch mit stationären Hindernissen in Betracht gezogen werden. Dieses erfordert eine zuverlässige Erkennung der Umgebung mit Hindernissen und ein Umgang mit Sensorunsicherheiten und Objekten die möglicherweise im Sensorschatten liegen. Um weiterhin eine geringe Rechenzeit von unter 20 ms zu behalten, wird vorgeschlagen, die Erweiterung auf komplexe Manöver auf mehreren Recheneinheiten zu parallelisieren.

In einem zweiten Ansatz wurde die Bewegungsprognose von einzelnen Fahrzeugen auf Basis eines Particle-Filters auf einer Bewegungsdatenbank durchgeführt. Zuvor an Kreuzungen aufgenommene Abbiegetrajektorien wurden in einer Bewegungsdatenbank zur Wissensrepräsentation abgelegt. Die Bewegungsprognose erfolgte dabei durch das Filtern von Referenztrajektorien aus einer Bewegungsdatenbank, die ähnlich der aktuell beobachteten Bewegungshistorie sind. Das Filtern der Hypothesen erfolgt über die Zeit. Die Trajektorien aus der Bewegungsprognose sind qualitativer Natur im Vergleich zu einem Modell eines Manövers.

Eine gleichzeitige Anwendung der datenbankbasierten Einzelfahrzeug-Bewegungsprognose auf zwei Fahrzeuge resultiert in einer unkorrelierten Prognose, dessen paarweise Betrachtung öfters eine Kollision der Fahrzeuge prognostiziert. Über ein Interaktionsmodell wurden die Bewegungsprognosen zwischen zwei Fahrzeugen in Beziehung gesetzt. Das Interaktionsmodell berücksichtigt bei Kollisionshypothesen die gegenseitige Sichtbarkeit der Fahrer und die Wahrscheinlichkeit einer Kollision, in Abhängigkeit von Time-To-Collision. Die Auswertung der Bewegungsprognose erfolgte anhand einer Gefahrenschätzung und einer Erkennung von Situationsklassen.

Eine Erweiterung der Bewegungsdatenbank auf die Bewegungsmuster zweier Fahrzeuge wurde im letzten Ansatz vorgestellt. Ein Interaktionsmodell ist dann nicht mehr notwendig, da diese Information in den Paaren der Bewegungsmuster liegt. Über eine nichtlineare Regression wird im Merkmalsraum von Manövern zwischen zwei Fahrzeugen eine niedrigdimensionale Mannigfaltigkeit trainiert. In der Anwendungsphase wird nach ähnlichen Hypothesenpaaren linear gesucht. Ein Vergleich der Bewegungsprognose mit einer linearen Extrapolation zeigt bei Abbiegemanövern eine genauere Schätzung des Fahrzeugzustandes mit einem Prognosehorizont von

2.52 s. Ein Vergleich der Bewegungsprognose über Trajektorienpaar-Mannigfaltigkeit zeigt eine höhere Prognosegenauigkeit bei Abbiegemanövern als eine Extrapolation der Bewegung über ein Einspurmodell.

Eine Kombination der Gefahrenschätzung mit einer Aufmerksamkeitserkennung würde die Zuverlässigkeit bei der Erkennung einer gefährlichen Situation erhöhen. Generell könnten beliebige Ursachen für Unfälle wie Müdigkeit, Aufmerksamkeit oder Einfluss von Rauschmitteln mit kinematischen Daten zusammen betrachtet werden.

Diese Arbeit stellte unterschiedliche Ansätze zur Prognose von Fahrzeugbewegungen und gefährlichen Situationen vor. Im Fokus liegt der Umgang mit Unsicherheiten bezüglich des Fahrerverhaltens. Eine erfolgreiche Demonstration der Gefahrenschätzung im Realverkehr unterstreicht die Praktikabilität der Entwicklung und weist einen möglichen Weg für die zukünftige Situationsanalyse.

Literaturverzeichnis

- [1] ACTIV: *Adaptive und kooperative Technologien für den intelligenten Verkehr*. <http://www.aktiv-online.org/>, . – [Letzter Aufruf: 09. Feb. 2012]
- [2] ALTHOFF, Matthias ; STURBERG, Olaf ; BUSS, Martin: Model-based probabilistic collision detection in autonomous driving. In: *Trans. Intell. Transport. Sys.* 10 (2009), June, S. 299–310. – ISSN 1524–9050
- [3] AOUBE, G. S. ; HOW, J. P.: Using Support Vector Machines and Bayesian Filtering for Classifying Agent Intentions at Road Intersections / Massachusetts Institute of Technology. Cambridge, MA, September 2009 (ACL09-02). – Forschungsbericht. – Aerospace Controls Lab
- [4] AOUBE, G. S. ; LUDERS, B. D. ; LEE, K. K. H. ; LEVINE, D. S. ; HOW, J. P.: Threat Assessment Design for Driver Assistance System at Intersections. In: *IEEE Conference on Intelligent Transportation Systems* (2010), September
- [5] BARROIS, Björn ; HRISTOVA, Stela ; WÖHLER, Christian ; KUMMERT, Franz ; HERMES, Christoph: 3D Pose Estimation of Vehicles Using a Stereo Camera. In: *IEEE Intelligent Vehicles Symposium*. Xi'an, China, 03/06/2009 2009
- [6] BARTH, Alexander ; PFEIFFER, David ; FRANKE, Uwe: Vehicle Tracking at Urban Intersections Using Dense Stereo. In: *3rd Workshop on Behaviour Monitoring and Interpretation, BMI*. Ghent, Belgium, 11 2009, S. 47–58
- [7] BAUER, H. ; STUTTGART, Robert Bosch G.: *Autoelektrik, Autoelektronik*. Vieweg, 2002 (Bosch. Kraftfahrzeugtechnik). – ISBN 9783528138721
- [8] BELLMAN, Richard: *Dynamic Programming*. Dover Publications, 1957. – ISBN 9780486428093
- [9] BERGROTH, L. ; HAKONEN, H. ; RAITA, T.: A survey of longest common subsequence algorithms. In: *String Processing and Information Retrieval, 2000. SPIRE 2000. Proceedings. Seventh International Symposium on*. A Coruña , Spain, 2000, S. 39–48

- [22] EIDEHALL, Andreas ; PETERSSON, Lars: Statistical Threat Assessment for General Road Scenes Using Monte Carlo Sampling. In: *IEEE Transactions on Intelligent Transportation Systems* 9 (2008), Nr. 1, S. 137 – 147
- [23] ERICSON, C.: *Real-Time Collision Detection*. Elsevier, 2005 (Morgan Kaufmann Series in Interactive 3D Technology Bd. 1). – ISBN 9781558607323
- [24] FARMER, Michael E. ; HSU, Rein lien ; JAIN, Anil K.: Interacting Multiple Model (IMM) Kalman Filters for Robust High Speed Human Motion Tracking. In: *16 th Intl. Conf on Pattern Recog., Vol.*, 2002, S. 20–23
- [25] FRANKE, Uwe ; RABE, Clemens ; BADINO, Hernán ; GEHRIG, Stefan: 6D-Vision: Fusion of Stereo and Motion for Robust Environment Perception. In: KROPATSCH, Walter (Hrsg.) ; SABLATNIG, Robert (Hrsg.) ; HANBURY, Allan (Hrsg.): *Pattern Recognition* Bd. 3663. Springer Berlin / Heidelberg, 2005, S. 216–223
- [26] GESAMTVERBAND DER DEUTSCHEN VERSICHERUNGSWIRTSCHAFT E.V.: Demonstration von Notbrems- und Auffahrwarnsystemen am Pkw. 2009. – Forschungsbericht
- [27] GILLESPIE, T. N.: *Fundamentals of Vehicle Dynamics*. Warrendale, PA : Society of Automotive Engineers, 1992
- [28] GOLUB, Gene H. ; VAN LOAN, Charles F.: *Matrix Computations (Johns Hopkins Studies in Mathematical Sciences)(3rd Edition)*. 3rd. The Johns Hopkins University Press, 1996. – ISBN 0801854148
- [29] GOMER, Viktor: *Optimierung eines Ansatzes zur Gefahrenbewertung in Kreuzungssituationen*, Universität Bielefeld, Diplomarbeit, 2011
- [30] GRABE, M.: *Measurement Uncertainties in Science and Technology*. Physica-Verlag, 2005. – ISBN 9783540273196
- [31] HALL, Edward T.: *The hidden dimension*. Doubleday, 1969 (A Doubleday Anchor book ; 609). – XII, 217 S. : Ill., graph. Darst.. – ISBN 0–385–08476–5
- [32] HAYASHI, Toshinori ; YAMADA, Keiichi: Predicting Unusual Right-turn Driving Behavior at Intersection. In: *Proc. of 2009 IEEE Intelligent Vehicles Symposium* (2009), June
- [33] HERMES, Christoph: *Aktionserkennung und -prädiktion mittels Trajektorienklassifikation*, Universität Bielefeld, Doktorarbeit, 2012
- [34] HERMES, Christoph ; EINHAUS, Julian ; HAHN, Markus ; WÖHLER, Christian ; KUMMERT, Franz: Vehicle tracking and motion prediction in complex urban scenarios. In: *IEEE Intelligent Vehicles Symposium (IV)*, 2010, S. 26–33

- [35] HERMES, Christoph ; WIEST, Jürgen ; WÖHLER, Christian ; KRESSEL, Ulrich ; KUMMERT, Franz: Manifold-based Motion Prediction. In: *Proc. 6. Dortmunder Auto-Tag*, 2011
- [36] HERMES, Christoph ; WÖHLER, Christian ; SCHENK, Konrad ; KUMMERT, Franz: Long-term Vehicle Motion Prediction, 2009, S. 652–657
- [37] HILLENBRAND, Jörg ; SPIEKER, Andreas M. ; KROSCHER, Kristian: Efficient Decision Making for a Multi-Level Collision Mitigation System. In: *2006 IEEE Intelligent Vehicles Symposium 29* (2006), Nr. 6, S. 460–465
- [38] HORN, Berthold K. P.: Closed-form solution of absolute orientation using unit quaternions. 4 (1987), S. 629–642
- [39] JOLLIFFE, I.T.: *Principal Component Analysis*. Springer Verlag, 1986
- [40] KÄFER, Eugen ; HERMES, Christoph ; WÖHLER, Christian ; KUMMERT, Franz ; RITTER, Helge: Recognition and Prediction of Situations in Urban Traffic Scenarios. In: *International Conference on Pattern Recognition 0* (2010), S. 4234–4237. – ISSN 1051–4651
- [41] KÄFER, Eugen ; HERMES, Christoph ; WÖHLER, Christian ; RITTER, Helge ; KUMMERT, Franz: Recognition of Situation Classes at Road Intersections. In: *Proc. Int. Conf. on Robotics and Automation*, 2010
- [42] KÄFER, Eugen ; HERMES, Christoph ; WÖHLER, Christian ; RITTER, Helge ; KUMMERT, Franz: Situation analysis at road intersections. In: *Proc. 5. Dortmunder Auto-Tag*. Dortmund, Germany, 2010
- [43] KALMAN, Rudolph E.: A New Approach to Linear Filtering and Prediction Problems. In: *Transactions of the ASME–Journal of Basic Engineering* 82 (1960), Nr. Series D, S. 35–45
- [44] KLANKE, Stefan: *Learning Manifolds with the Parametrized Self-Organizing Map and Unsupervised Kernel Regression*, University of Bielefeld, PhD Thesis, 2007
- [45] KLANKE, Stefan ; RITTER, Helge: A leave-k-out cross-validation scheme for unsupervised kernel regression. In: *Proceedings of the 16th international conference on Artificial Neural Networks - Volume Part II*. Berlin, Heidelberg : Springer-Verlag, 2006 (ICANN'06). – ISBN 3–540–38871–0, 978–3–540–38871–5, S. 427–436
- [46] KOFAS: *Forschungsinitiative Ko-FAS*. <http://www.ko-fas.de/>, . – [Letzter Aufruf: 09. Feb. 2012]
- [47] KOHONEN, Teuvo (Hrsg.): *Self-organizing maps*. Secaucus, NJ, USA : Springer-Verlag New York, Inc., 1997. – ISBN 3–540–62017–6

- [48] KRAMER, F.: *Passive Sicherheit Von Kraftfahrzeugen: Biomechanik- Simulation- Sicherheit Im Entwicklungsprozess*. Vieweg+Teubner Verlag, 2008 (Atz/Mtz-Fachbuch). – ISBN 9783834805362
- [49] KUIPERS, L. ; NIEDERREITER, H.: *Uniform distribution of sequences*. Wiley, 1974 (Pure and applied mathematics). – ISBN 9780471510451
- [50] LAUER, Christoph ; BOTSCH, Michael: Complexity Reduction Using the Random Forest Classifier in a Collision Detection Algorithm. In: *2010 IEEE Intelligent Vehicles Symposium*. San Diego : IEEE, 2010
- [51] LAVALLE, Steven M.: *Rapidly-Exploring Random Trees: A New Tool for Path Planning*. 1998. – Forschungsbericht
- [52] LLOYD, Stuart P.: Least squares quantization in pcm. In: *IEEE Transactions on Information Theory* 28 (1982), S. 129–137
- [53] MAHALANOBIS, P. C.: On the generalised distance in statistics. In: *Proceedings National Institute of Science, India* Bd. 2, 1936, S. 49–55
- [54] MAIER, David: The Complexity of Some Problems on Subsequences and Supersequences. In: *J. ACM* 25 (1978), April, Nr. 2, S. 322–336. – ISSN 0004–5411
- [55] MASON, J.C. ; HANDSCOMB, D.C.: *Chebyshev polynomials*. Chapman & Hall/CRC, 2003. – ISBN 9780849303555
- [56] MEINICKE, Peter ; KLANKE, Stefan ; MEMISEVIC, Roland ; RITTER, Helge J.: Principal Surfaces from Unsupervised Kernel Regression. In: *IEEE Trans. on Pattern Analysis and Machine Intelligence* 27 (2005), Sep, Nr. 9, S. 1379–1391
- [57] MEISTER, Andreas: *Numerik linearer Gleichungssysteme, Eine Einfuehrung in moderne Verfahren*. Braunschweig, Wiesbaden : Vieweg Verlag, 1999. – ISBN 3–528–03135–2
- [58] METROPOLIS, N. ; ROSENBLUTH, A.W. ; ROSENBLUTH, M.N. ; TELLER, A. H. ; TELLER, E.: Equations of state calculations by fast computing machines. In: *Journal of Chemical Physics* 21 (1953), S. 1087–1092
- [59] MITSCHKE, Manfred: *Dynamik der Kraftfahrzeuge Band C: Fahrverhalten*. Berlin : Springer-Verlag, 1990. – XI, 446 S. : graph. Darst.
- [60] MOTWANI, R. ; RAGHAVAN, P.: *Randomized Algorithms*. Cambridge University Press, 1997
- [61] PRESS, William ; TEUKOLSKY, Saul ; VETTERLING, William ; FLANNERY, Brian: *Numerical Recipes in C*. 2nd. Cambridge University Press, 1992

- [62] RIEDMILLER, Martin ; BRAUN, Heinrich: A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm. In: *IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS*, 1993, S. 586–591
- [63] RITTER, Helge J. ; MARTINETZ, Thomas ; SCHULTEN, Klaus: *Neuronale Netze - eine Einführung in die Neuroinformatik selbstorganisierender Netzwerke*. Bonn : Addison Wesley Verlag, 1990
- [64] ROTHEN, Christian: *Trajektorienplanung im Kreuzungsbereich*, Universität Bielefeld, Diplomarbeit, 2010
- [65] ROWEIS, Sam T. ; SAUL, Lawrence K.: Nonlinear dimensionality reduction by locally linear embedding. In: *SCIENCE* 290 (2000), S. 2323–2326
- [66] SCHÜRMAN, Jürgen: *Pattern classification: a unified view of statistical and neural approaches*. New York, USA : John Wiley & Sons, 1996. – ISBN 0-471-13534-8
- [67] SCHWARZ, Hans R. ; KÖCKLER, Norbert: *Numerische Mathematik*. B.G. Teubner Verlag / GWV Fachverlage GmbH, Wiesbaden, 2006
- [68] SIDENBLADH, Hedvig ; BLACK, Michael J. ; SIGAL, Leonid: *Implicit Probabilistic Models of Human Motion for Synthesis and Tracking*. London, UK : Springer-Verlag, 2002. – ISBN 3-540-43745-2, S. 784–800
- [69] SNYMAN, J. A.: *Practical Mathematical Optimization: An Introduction to Basic Optimization Theory and Classical and New Gradient-Based Algorithms*. Second. Springer-Verlag New York, Inc., 2005 (Applied Optimization, Vol. 97)
- [70] STATISTISCHES BUNDESAMT: Verkehr. Verkehrsunfälle. Fachserie 8, Reihe 7. Wiesbaden, 2010 (2). – Fachserie 8, Reihe 7
- [71] STOER, Josef: *Numerische Mathematik 1*. 8. Auflage. Berlin, Heidelberg : Springer-Verlag, 1999. – ISBN 3-540-66154-9
- [72] TAMKE, A. ; DANG, Thao ; BREUEL, G.: A flexible method for criticality assessment in driver assistance systems. In: *Intelligent Vehicles Symposium (IV), 2011 IEEE*. Baden-Baden, 2011. – ISSN 1931-0587, S. 697–702
- [73] THRUN, Sebastian ; BURGARD, Wolfram ; FOX, Dieter: *Probabilistic Robotics (Intelligent Robotics and Autonomous Agents series)*. The MIT Press, 2005 (Intelligent robotics and autonomous agents). – ISBN 0262201623
- [74] VERKEHRSClub DEUTSCHLAND: *VCD Masterplan Vision Zero*. 2009. – <http://www.vcd.org/visionzero.html>, [Letzter Aufruf: 08. Juni 2012]
- [75] VLACHOS, Michail ; KOLLIOS, George ; GUNOPULOS, Dimitrios: Elastic Translation Invariant Matching of Trajectories. 58 (2005), Nr. 2-3, S. 301–334. – ISSN 0885-6125

- [76] WHO: *World Health Day 2004 — World Health Organization*. <http://www.who.int/world-health-day/previous/2004/en/>, 2004. – [Letzter Aufruf: 09. Feb. 2012]
- [77] WINNER, H. ; HAKULI, S. ; WOLF, G.: *Handbuch Fahrerassistenzsysteme: Grundlagen, Komponenten und Systeme für aktive Sicherheit und Komfort*. Vieweg + Teubner, 2009 (ATZ-MTZ-Fachbuch). – ISBN 9783834802873
- [78] WU, Shunguang ; DECKER, Stephen ; CHANG, Peng ; CAMUS, Theodore ; ELEDATH, Jayan: Collision sensing by stereo vision and radar sensor fusion. In: *Trans. Intell. Transport. Sys.* 10 (2009), Dezember, Nr. 4, S. 606–614. – ISSN 1524–9050
- [79] ZHA, Hongyuan Z. ; ZHANG, Zhenyue: Isometric Embedding and Continuum ISOMAP. In: *In Proceedings of the Twentieth International Conference on Machine Learning*, 2003, S. 864–871
- [80] ZHANG, Yizhen ; ANTONSSON, E.K. ; GROTE, K.: A new Threat Assessment Measure for Collision Avoidance Systems. In: *Intelligent Transportation Systems Conference, 2006* (2006), September

Anhang

Eigene Publikationen

KÄFER, Eugen ; HERMES, Christoph ; WOHLER, Christian ; KUMMERT, Franz ; RITTER, Helge: Recognition and Prediction of Situations in Urban Traffic Scenarios. In: *International Conference on Pattern Recognition 0* (2010), S. 4234–4237. – ISSN 1051–4651

KÄFER, Eugen ; HERMES, Christoph ; WÖHLER, Christian ; RITTER, Helge ; KUMMERT, Franz: Recognition of Situation Classes at Road Intersections. In: *Proc. Int. Conf. on Robotics and Automation*, 2010

KÄFER, Eugen ; HERMES, Christoph ; WÖHLER, Christian ; RITTER, Helge ; KUMMERT, Franz: Situation analysis at road intersections. In: *Proc. 5. Dortmunder Auto-Tag*. Dortmund, Germany, 2010

Betreute Diplomarbeiten

ROTHEN, Christian: *Trajektorienplanung im Kreuzungsbereich*, Universität Bielefeld, Diplomarbeit, 2010

GOMER, Viktor: *Optimierung eines Ansatzes zur Gefahrenbewertung in Kreuzungssituationen*, Universität Bielefeld, Diplomarbeit, 2011