ulm university universität ulm

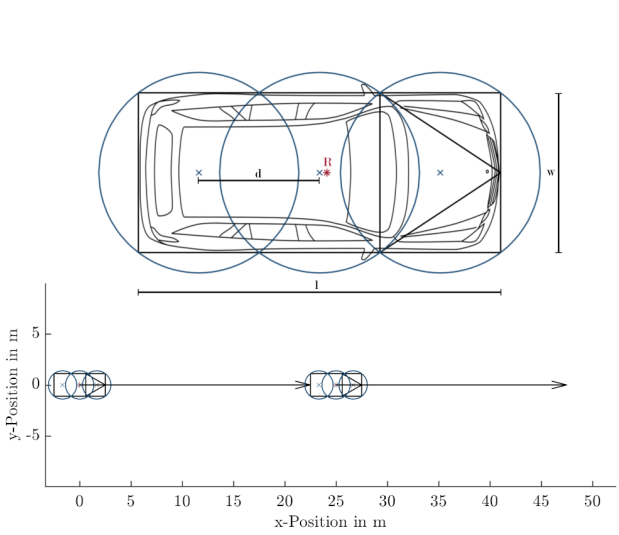

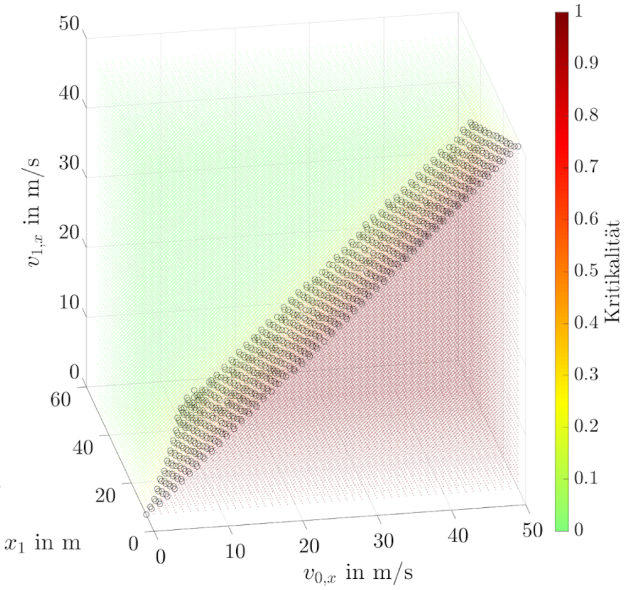

Statistische Ermittlung risikobehafteter Fahrsituationen für hochautomatisiertes Fahren zur Absicherung der Funktionssicherheit

Daniel Stumper

Band 34

Schriftenreihe des Instituts für Mess-, Regel- und Mikrotechnik

Daniel Tobias Stumper

Statistische Ermittlung risikobehafteter Fahrsituationen für hochautomatisiertes Fahren zur Absicherung der Funktionssicherheit

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

Herausgeber:
Prof. Dr.-Ing. Klaus Dietmayer

Band 34

Daniel Tobias Stumper

Statistische Ermittlung risikobehafteter Fahrsituationen für hochautomatisiertes Fahren zur Absicherung der Funktionssicherheit

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

Dissertation, Universität Ulm,
Fakultät für Ingenieurwissenschaften, Informatik und Psychologie, 2020

Impressum

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

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

Diese Veröffentlichung ist im Internet auf dem Open-Access-Repositorium der Universität Ulm (https://oparu.uni-ulm.de) verfügbar und dort unter der Lizenz “Standard” publiziert. Details zur Lizenz sind unter http://www.uni-ulm.de/index.php?id=50392 zu finden.

Institut für Mess-, Regel- und Mikrotechnik der Universität Ulm 2021

ISBN 978-3-941543-52-2 (E-Book)



ulm university universität
uulm

Statistische Ermittlung risikobehafteter Fahrsituationen für hochautomatisiertes Fahren zur Absicherung der Funktionssicherheit

DISSERTATION

zur Erlangung des akademischen Grades eines

DOKTOR-INGENIEURS
(Dr.-Ing.)

der Fakultät für Ingenieurwissenschaften, Informatik
und Psychologie der Universität Ulm

von

Daniel Tobias Stumper
aus Kirchheim unter Teck

Gutachter:	Prof. Dr.-Ing. Klaus Dietmayer
	Prof. Dr.-Ing. Bin Yang
Amtierender Dekan:	Prof. Dr.-Ing. Maurits Ortmanns

Ulm, 23.07.2020

Für Anne

Kurzfassung

Die vorliegende Arbeit beschäftigt sich mit der Fragestellung, wie Verkehrssituationen charakterisiert werden können, um dadurch kritische Vertreter zu bestimmen und den Testaufwand zu reduzieren. Bei der großflächigen Einführung automatisierter Fahrzeuge besteht eine Herausforderung darin, die Sicherheit für Personen innerhalb und außerhalb der Fahrzeuge zu gewährleisten. Neben anderen großen technischen Herausforderungen, wie dem korrekten Umgang mit Sensordaten, dem richtigen Ableiten der Umweltinformationen und der Umsetzung eines angenehmen Fahrgefühls, steht die Absicherung der Funktionssicherheit. Bisher beruht die Auswahl der zu untersuchenden Fahrsituationen auf Expertenwissen und auf dem Einfahren großer Kilometerumfänge. Durch die fortschreitende Entwicklung der Fahrzeuge werden immer geringere Fehlerraten für einzelne Systeme gefordert. Die Absicherung ist dabei technisch und wirtschaftlich nicht mehr durch Fahrversuche allein zu erbringen. An diesem Punkt setzt die vorliegende Arbeit an, indem Situationen mathematisch modelliert werden und somit eine statistische Auswertung ermöglicht wird. Dies erlaubt alle modellierbaren Situationen mit beliebiger Auflösung zu untersuchen, wozu auch deren zeitlicher Verlauf berücksichtigt werden muss. Hierzu wird das Konzept der Episoden eingeführt, wodurch eine mathematische Darstellung für den möglichen Verlauf einzelner Situationen geschaffen wird. Durch die Auswertung mehrerer Episoden ergibt sich die Möglichkeit der zugrunde liegenden Situationen ein Risiko zuzuweisen, im Folgenden Kritikalität genannt.

Durch dieses Vorgehen ist es weiterhin möglich, einer beliebig großen Menge an Situationen eine Kritikalität zuzuordnen, wodurch verschiedene Eigenschaften der Daten ausgewertet werden können. Die Erkennung der Grenzen zwischen kritischen und unkritischen Situationen erlaubt es beispielsweise, diese verstärkt bei Fahrtests zu verwenden. Die Idee dahinter ist es den Testaufwand zu reduzieren, indem nicht hauptsächlich Situationen gefahren werden, welche einerseits sicher unkritisch oder andererseits sicher kritisch sind. Es sollen solche Situationen gefunden werden bei denen das Testfahrzeug seine Funktion beweisen kann, um eine Situation vom kritischen in den unkritischen Bereich zu bewegen. Zusätzlich erlaubt das Wissen um die Beschaffenheit der kritischen Bereiche eine tiefgehende Analyse und Berücksichtigung bei der Entwicklung neuer Fahrfunktionen.

Abstract

The present thesis works on characterizing traffic situations in order to determine critical representatives and to reduce the testing effort. One challenge in the large-scale introduction of automated vehicles is to ensure the safety of people inside and outside of the vehicles. The validation of functional safety is a major technical challenge in addition to others, such as the correct handling of sensor data, the correct derivation of environmental information and the implementation of a comfortable driving experience. Up to now, the selection of driving situations to be investigated has been based on expert knowledge and large scale test driving. Nevertheless, the accepted error tolerances decline as the vehicles get more sophisticated. Therefore, the validation and verification of functional safety cannot be provided by test driving alone. The present work intervenes at this point by modelling situations mathematically and thus enabling a statistical evaluation. This allows to investigate all depictable situations with arbitrary resolution while considering their temporal process as well. For this purpose, the concept of episodes is introduced, which provides a mathematical representation of a situation's possible temporal process. By evaluating several episodes belonging to one situation this situation can be assessed with a risk, hereinafter referred to as criticality.

This procedure also enables the criticality assignment to an arbitrarily large number of situations, allowing various data properties to be evaluated. For example, the detection of boundaries between critical and non-critical situation domains allows the usage of this boundary situations for driving tests. The purpose is to reduce the testing effort by not using driving situations that are certainly uncritical or certainly critical. Instead, focusing on situations where the test vehicle can prove its reliability by transferring a situation from the critical to the non-critical range. In addition, the knowledge of the nature of the critical areas allows in-depth analysis and consideration in the development of new driving functions.

Inhaltsverzeichnis

1 Einleitung **1**
- 1.1 Motivation . . . 2
- 1.2 Terminologie . . . 3

2 Stand der Technik **5**
- 2.1 Automatisiertes Fahren . . . 5
- 2.2 Absicherung im Rahmen der ISO 26262 . . . 6
- 2.3 Aktuelle Sicherheitsansätze . . . 8
- 2.4 Fahrzeug- und Verkehrsmodelle . . . 10
- 2.5 Ansätze zur Trajektoriengenerierung . . . 11
- 2.6 Sicherheitsmaße und Risikobewertung . . . 12

3 Grundlagen **15**
- 3.1 Situation . . . 15
- 3.2 Episode . . . 18
- 3.3 Episodenraum . . . 19
- 3.4 Situationsraum . . . 19
- 3.5 Kritikalität . . . 20
- 3.6 Polynomapproximation und Tschebyschow Polynome . . . 22
- 3.7 Monte-Carlo-Methode . . . 25
- 3.8 *Gaussian Process Latent Variable Model* . . . 27
- 3.9 *Support Vector Machine* . . . 30

4 Datensatzgenerierung **33**
- 4.1 Trajektorienberechnung . . . 33
- 4.2 Episodengenerierung . . . 34
  - 4.2.1 Episodenrasterung . . . 35
  - 4.2.2 Monte-Carlo-Methode . . . 37
- 4.3 Episodenbewertung . . . 38
  - 4.3.1 Referenzpunktmethode . . . 39
  - 4.3.2 Kreismethode . . . 40
- 4.4 Kritikalitätsberechnung . . . 41
- 4.5 Situationsbewertung . . . 45
- 4.6 Datensätze . . . 47

5 Auswertung der Situationsdatensätze **55**
5.1 Motivation . . . 55
5.2 *Gaussian Process Latent Variable Model* . . . 56
5.2.1 *Gaussian Process Latent Variable Model* (GPLVM) Auswertung des 5D Datensatzes . . . 56
5.2.2 GPLVM Auswertung des 3D Datensatzes . . . 59
5.2.3 GPLVM Diskussion . . . 61
5.3 Charakterisierung mittels *Support Vector Machine* . . . 62
5.3.1 Auswertung der 3D-Datensätze . . . 64
5.3.2 Auswertung der 5D-Datensätze . . . 85
5.4 Diskussion . . . 90
5.4.1 Kritikalitätsgrenze . . . 90
5.4.2 Stützvektoren . . . 91

6 Auswertung von Realdaten **93**
6.1 Ursprung und Art der Aufnahmen . . . 93
6.2 Vorbereitung der Aufnahmen . . . 94
6.3 Auswahl der betrachteten Fahrzeuge . . . 94
6.4 Statistiken der Datensätze . . . 96
6.5 Darstellung im Situationsraum . . . 98
6.6 Interpretation der Ergebnisse . . . 99

7 Zusammenfassung und Ausblick **101**
7.1 Zusammenfassung . . . 101
7.2 Ausblick . . . 102

A Eigene Veröffentlichungen **103**

Akronyme **105**

Symbolverzeichnis **107**

Literaturverzeichnis **109**

Kapitel 1

Einleitung

Das erste Fahrzeug mit Verbrennungsmotor wurde 1886 von Carl Benz gebaut und 1888 zum Patent angemeldet. Hieraus entstand das heutige Automobil. Auch wenn die Geschichte der nicht durch Lebewesen angetriebenen Fahrzeuge, zum Beispiel solche mit Dampfantrieb, schon früher beginnt, gilt das Jahr 1888 als Geburtsjahr des modernen Automobils. Seitdem sind über 130 Jahre vergangen und bezüglich Technik, Benutzerfreundlichkeit und Sicherheit wurden unzählige Verbesserungen erreicht. Wichtige Erfindungen wie Scheibenwischer, Sicherheitsgurt, Airbag, und elektronisches Stabilitätsprogramm sind nur einige Beispiele, welche die Sicherheit des Fahrens nachhaltig erhöht haben. Fahrassistenzfunktionen wie *Adaptive Cruise Control* (Abstandsregeltempomat) (ACC) können den, noch ausschließlich menschlichen Fahrer, unterstützen. Den weltweit rund 1,3 Milliarden Kraftfahrzeugen[1] steht die nächste große Entwicklung bevor, das *automatisierte Fahren.*

Dabei soll dem Fahrer[2] jegliche Fahraufgabe abgenommen und ihm somit die Möglichkeit anderweitiger Tätigkeiten während des Fahrens gegeben werden. Praktisch alle Automobilhersteller, Zulieferer, selbst Technologiefirmen arbeiten daran, wenn auch teilweise an unterschiedlichen Stufen der Automatisierung. Seit 2014 existiert die Norm SAE J3016, welche sechs Stufen der Automatisierung unterscheidet [SAE]:

0. Keine Automatisierung
1. Fahrerassistenz
2. Teilautomatisierung
3. Bedingte Automatisierung
4. Hochautomatisierung
5. Vollautomatisierung

[1] `https://de.statista.com/statistik/daten/studie/244999/umfrage/weltweiter-pkw-und-nutzfahrzeugbestand/`, abgerufen 28.09.2018

[2] (Sicherheits-)*Fahrer* ist hier und im Folgenden explizit geschlechtsneutral, die fahrende Person kann männlich, weiblich oder divers sein (in beliebiger Reihenfolge).

Neben technischen Aspekten und Herausforderungen ist auch die Gewährleistung der Fahrsicherheit ein großes Forschungsgebiet. Etablierte Absicherungsmethoden, bei denen auf den menschlichen Fahrer als Rückfallebene zurückgegriffen werden kann, lassen sich nicht ohne Anpassungen auf die neuen Techniken übertragen. Auch die gängige Praxis, neue Funktionen durch ausgiebige Testfahrten zu testen, zu verbessern und abzusichern, führt zu einem immer größeren benötigten Kilometerumfang. Aktuelle Schätzungen gehen von über 6 Milliarden [WW15] Testkilometern aus, welche für die Absicherung eines automatisierten Fahrzeugs gefahren werden müssen. Daher besteht ein großes Einsparpotential in der Reduktion dieser Strecke durch effizientere Auswahl der Fahrszenarien, da bei einer durchschnittlichen Testfahrt nur ein geringer Teil aus interessanten Vorkommnissen besteht [GBH12].

1.1 Motivation

Durch die stetige Verbesserung der Sicherheit in modernen Personenkraftwagen (Pkw) konnte die Zahl der Verkehrstoten in Deutschland von über 8000 im Jahr 1991 auf unter 4000[3] im Jahr 2016 halbiert werden. Diese Zahl gilt es durch bessere Technik weiter zu senken. Ebenso werden jedes Jahr über 300 000 Personen im Straßenverkehr verletzt[4].

Ein großer Teil der Unfälle ist auf menschliches Versagen zurückzuführen, weshalb durch die Reduzierung des Faktors „Mensch“ in der Fahraufgabe auch eine Reduzierung der Unfälle erwartet wird [FK15].

Allerdings ist keine neue Technologie von Beginn an fehlerfrei, weshalb auch bei der Einführung automatisierter Fahrzeuge mit Unfällen, Verletzten und schlimmstenfalls Toten gerechnet werden muss. Darüber hinaus ist jeder, durch ein automatisiertes Fahrzeug verursachter, Unfall nur schwer von der Gesellschaft akzeptierbar. Insbesondere dann, wenn er einem durchschnittlichen, menschlichen Fahrer nicht unterlaufen wäre. Daher ist die höchstmögliche Sicherheit dieser Fahrzeuge gefordert und umzusetzen.

Je ausführlicher und ausgeprägter die dafür notwendigen Tests gestaltet sind, desto sicherer wird die getestete Funktion. Da solche Erprobungen sehr zeit- und kostenintensiv sind, besteht der Wunsch diese zu optimieren und nur die Szenarien zu testen, welche einen Erkenntnisgewinn versprechen. Durch eine Minimierung des

[3] `https://de.statista.com/statistik/daten/studie/185/umfrage/todesfalle-im-strassenverkehr/`, abgerufen 28.09.2018

[4] `https://de.statista.com/statistik/daten/studie/3396/umfrage/anzahl-der-strassenverkehrsunfaelle-mit-personenschaden/`, abgerufen 28.09.2018

Testaufwands können neue Funktionen in gleicher Zeit besser getestet werden.

1.2 Terminologie

Für die einheitliche Beschreibung des aktuellen Zustands aller Fahrzeuge und des zeitlichen Verlaufs werden zunächst geeignete Definitionen ermittelt. Da zu Beginn der Arbeiten in der Literatur noch keine einheitlichen Bezeichnungen verwendet wurden, werden für diese Arbeit folgende Begriffe definiert:

Situation
: Eine Situation beschreibt den momentanen Zustand aller Fahrzeuge unter Beobachtung. Es ist keine Information über zukünftige oder vergangene Situationen enthalten.

Episode
: Eine Episode beschreibt den zeitlichen Verlauf einer Situation. Somit entspricht der realen Bewegung der Fahrzeuge eine einzelne Episode, wobei beliebige Episoden von einer einzelnen Situation ausgehen können.

Kritikalität
: Als Kritikalität wird in dieser Arbeit die Höhe des Risikos einer Situation sowie einer Episode verwendet. Je nach Ausprägung handelt es sich hierbei um die Wahrscheinlichkeit eines Unfalls oder eines starken Brems- oder Ausweichvorgangs.

Episodenraum
: Raum aller Episoden, die aus einer Situation entstehen können. Die Dimension entspricht den verwendeten Episodenparametern.

Situationsraum
: Raum aller möglichen Situationen, welche betrachtet werden können. Die Anzahl der Fahrzeuge und die betrachteten Zustände definieren hierbei die Dimension, welche je nach Komplexität größer oder kleiner ausfällt.

Zwischenzeitlich wurden die Begriffe Szene, Situation, und Szenario in der Literatur vorgestellt [UMR+15a; UMR+15b], welche sich größtenteils mit den hier verwendeten Begriffen decken.

Aufbauend auf der mathematischen Definition der Begriffe, welche eine effiziente Handhabung und Berechnung ermöglichen, werden mehrere Ansätze zur Generierung

und Auswertung untersucht. Da aus einer Situation beliebig viele Episoden folgen können, ist eine schnelle und ausreichend vielfältige Generierung der Episoden notwendig. Hierbei wird zunächst ein deterministisches Verfahren untersucht, um bestimmte Episoden generieren zu können, wobei die Vielfältigkeit der berechneten Episoden auf den Eingabeparametern beruht.

Daher wird anschließend auf ein zufälliges Samplingverfahren eingegangen, wodurch die konkreten Episoden zwar nicht mehr direkt vorgegeben werden können, aber durch eine angemessen hohe Anzahl von Stichproben eine ausreichend hohe Abdeckung erreicht wird.

Nach der Optimierung und Festlegung der Auswertemethode einer einzelnen Situation wird auf die automatisierte Generierung beliebiger Situationen eingegangen. Dadurch wird eine großflächige Auswertung von Situationen ermöglicht, welche eine tiefere Analyse des Situationsraum zulässt.

Die weitere Arbeit gliedert sich wie folgt: Mit Kapitel 2 wird ein Überblick über den aktuellen Stand der Technik gegeben. In Kapitel 3 werden die definierten Begriffe detaillierter beschrieben und die verwendeten Verfahren vorgestellt. Kapitel 4 befasst sich mit der Erstellung und Bewertung der verwendeten Datensätze. In Kapitel 5 werden die Datensätze ausgewertet, wodurch Rückschlüsse auf die Beschaffenheit der Situationsräume gezogen werden können. Kapitel 6 zeigt, wie aus aufgenommen Realdaten Situationen extrahiert werden können und vergleicht diese mit den Datensätzen aus den vorangegangen Kapiteln. Die Arbeit schließt mit Kapitel 7, welches die Ziele und Ergebnisse der Arbeit zusammenfasst und einen Ausblick für zukünftige Arbeiten gibt.

Kapitel 2

Stand der Technik

Nachdem im vorigen Kapitel eine Einführung in das Thema und die Zielstellung der Arbeit gegeben wurde, wird in diesem Kapitel auf den aktuellen Stand der Technik eingegangen. Hierbei wird zunächst allgemein auf das automatisierte Fahren und speziell auf die Absicherung mittels ISO 26262 eingegangen. Anschließend erfolgt ein Einblick in Themenbereiche und Methoden, welche im Rahmen der Arbeit betrachtet und verwendet werden.

2.1 Automatisiertes Fahren

Spätestens seit der *Defense Advanced Research Projects Agency* (DARPA) *Grand Challenge* 2005, einem Rennen zwischen autonomen Roboterfahrzeugen, sind automatisierte Fahrzeuge keine weit entfernte Zukunftsvision mehr, sondern technisch umsetzbar [TMD+06]. Seit 2009 arbeitet Google an einem fahrerlosen Pkw und hat die Forschung und Entwicklung 2016 in die Firma *Waymo* ausgegliedert [Ros17].

Ende 2014 ging mit dem Model S und der Fahrerassistenzsoftware *Autopilot* der Firma Tesla eines der ersten Fahrzeuge in den Serienverkauf, welches explizit mit seinen automatisierten Fahreigenschaften beworben wurde. Über die Zeit wurde diese Software stetig verbessert und beinhaltet aktuell die Funktionen ACC, *Autosteer*, *Speed Assist*, *Autopark*, sowie weitere Sicherheitsfunktionen. Einer der ersten und meist beachteten Unfälle eines Teslas im *Autopilot*-Modus fand 2016 statt, als ein Model S ungebremst in einen Lastkraftwagen (Lkw)-Anhänger fuhr, und der Fahrer tödlich verletzt wurde. Dieser Unfall veranlasste die *National Highway Traffic Safety Administration* (NHTSA) dazu, den Autopilot Teslas genau zu untersuchen. Dabei wurden keine Fehler im *Autonomous Emergency Braking* (Notbremsassistent) (AEB) oder Autopilot festgestellt, da alle Systeme wie ausgelegt funktionierten [Hab17]. Das AEB ist auf Auffahrunfälle ausgelegt und auf Rückfronten spezialisiert. Unfälle

mit kreuzenden Fahrzeugen gehören nicht zur aufgeführten Funktion. In dem Untersuchungsbericht wurden auch die anderen Funktionen des *Autopiloten* untersucht. Dieser, und jeder andere Unfall welcher im Bezug zu *Advanced Driver Assistance Systems* (Fahrerassistenzsysteme) (ADAS) steht, verdeutlicht die Notwendigkeit von vielfältigen Tests und detaillierten Funktionsbeschreibungen.

Das *California Department of Motor Vehicles* (DMV) fordert seit 2014 ausführliche jährliche Berichte von allen Firmen, welche im Staat Kalifornien automatisierte Testfahrzeuge im öffentlichen Straßenverkehr bewegen[5]. Da zu dieser Zeit die meisten Firmen, die am automatisierten Fahren forschen, im *Silicon Valley* angesiedelt oder zumindest vertreten waren, geben diese Berichte einen guten Überblick über den getätigten Erprobungsaufwand. Während es 2015 sieben Firmen waren, welche in Kalifornien Testfahrten durchführten, waren es im Jahr 2017 bereits 20 Firmen. Die Fahrleistung der verschiedenen Firmen unterscheidet sich stark, wobei Waymo mit über 1 000 000 km heraussticht. Dabei wurde der automatisierte Fahrbetrieb 124 Mal ungeplant beendet. Dies zeigt zum einen den Anstieg des Erprobungsaufwands im Bereich des automatisierten Fahrens. Zum anderen zeigen die ungeplanten Eingriffe, dass weiterhin Situationen auftreten, welche eine übergeordnete Sicherheitsinstanz benötigen. Aktuell ist dies der Sicherheitsfahrer, in Zukunft könnte dies eine Person durch teleoperiertes Fahren übernehmen [TCL14]. Inwieweit dies online und im großen Maßstab funktionieren kann, bleibt abzuwarten.

Auch andere Fahrzeugklassen als der Pkw werden automatisiert, da die Automatisierung als der größte Umsatztreiber bis im Jahr 2025 erwartet wird [McK16]. Der automatisierte und elektrifizierte Lkw der Firma Daimler[6] ist ein Beispiel dafür [FBZS95].

Zusätzlich findet auch im Öffentlicher Personennahverkehr (ÖPNV) eine immer stärkere Automatisierung statt, ebenso wie in der (Fracht-)Schifffahrt.

2.2 Absicherung im Rahmen der ISO 26262

Die ISO 26262 - *Road Vehicles – Functional Safety* aus dem Jahr 2011 [ISO11] wird zur systematischen Absicherung von Elektrik- und Elektronik-Systemen (E/E-System) in Pkw verwendet. Aus ihr leitet sich die Notwendigkeit ab, Testfälle und Szenarien bereitzustellen. Diese werden für die Gefahren- und Risikoanalyse (G&R)

[5] `https://www.dmv.ca.gov/portal/dmv/detail/vr/autonomous/testing`, abgerufen am 27. September 2018

[6] `https://www.daimler.com/innovation/autonomes-fahren/mercedes-benz-future-truck.html`, abgerufen am 28. Februar 2020

und später für die Verifikation der Funktionssicherheit benötigt, siehe Abbildung 2.1. Die Norm beschreibt einen Leitfaden, wie das Risiko, welches von einem E/E-System ausgeht, eingeschätzt und abgesichert werden kann. Weite Teile berufen sich dabei auf Expertenwissen, sei es bei der Einschätzung der Häufigkeit bestimmter Umstände oder der Beherrschbarkeit schwieriger Fahraufgaben durch den Fahrer. Zur Unterstützung und zur Ableitung einer Auftrittswahrscheinlichkeit können Statistiken über Wetter, Verkehr und Straßentopologie herangezogen werden. Zusätzlich können Probandenstudien durchgeführt werden, um verschiedene Fahraufgaben zu untersuchen und auszuwerten. Auch die schlussendliche Entscheidung, welche Szenarien zur genauen Untersuchung herangezogen werden, erfolgt durch Expertenwissen. Daher besteht ein Hauptanliegen dieser Arbeit darin, diesen Prozess, durch die Identifikation interessanter Testsituationen zur Absicherung neuer Fahrfunktionen, zu unterstützen. Aktuell werden große Testkilometerumfänge eingefahren, um neue Fahrfunktionen zu testen, wobei ein branchenüblicher Wert 150 000 km ist[7]. Hierbei ergibt sich die Herausforderung Situationen zu beobachten, welche geeignet sind das zu testende System vielfältig auf die Probe zu stellen.

Allgemein gliedert sich die Norm in folgende zehn Bände:

1. Vocabulary
2. Management of functional safety
3. Concept phase
4. Product development at the system level
5. Product development at the hardware level
6. Product development at the software level
7. Production and operation
8. Supporting processes
9. Automotive Safety Integrity Level (ASIL)-oriented and safety-oriented analyses
10. Guideline

[7] `https://www.telekom.com/de/medien/medieninformationen/detail/testfahrten-neue-software-versteht-den-erlkoenig-besser-534198`, abgerufen am 28. Februar 2020

Unter *funktionale Sicherheit (FuSi)* wird in der Norm derjenige Zustand bezeichnet, bei dem keine unvertretbaren Risiken bei sicherheitsrelevanten E/E-Systemen auftreten. Das Risiko eines Schadens ist hierbei dessen Auftrittswahrscheinlichkeit multipliziert mit dessen Schwere, wobei sich das Wort *Schaden* in diesem Zusammenhang stets auf Personenschaden bezieht. Reine Sachschäden werden in diesem Kontext nicht beachtet. Durch die erfolgreiche Anwendung der ISO 26262 werden bereits in der Entwicklungsphase systematische Fehler vermieden und Vorgaben zur Bewältigung etwaiger Fehler im laufenden Betrieb gemacht. Über die Richtlinie selbst als auch über deren Anwendung existieren mehrere Dissertationen [Hil12; Mai14; Wei13]. Dennoch ist sie mehr ein Leitfaden über Methoden, die bei der Entwicklung von sicherheitsrelevanten E/E-Systemen berücksichtigt werden sollen, als ein Prozess wie diese sicher gemacht werden können. Anhand der Richtlinie wurden auch Arbeiten zur elektronischen Bremse (*brake-by-wire*) [LHC+16], elektronischen Lenkung (*steer-by-wire*) [GHL14; Mar12] und zur Herausforderung im Umgang mit Fahrerassistenzsystemen [SRE+12] angefertigt.

Bei der G&R und bei der Verifikation der Funktionssicherheit werden Testfälle benötigt, in denen sich die Funktionsweise behaupten muss. Diese Testfälle werden meist durch Expertenwissen ermittelt, wodurch eine systematische und vollständige Betrachtung nicht sichergestellt ist. Als Unterstützung wird in dieser Arbeit eine Methode entwickelt, Testfälle zu generieren und eine Abschätzung über die Testabdeckung zu liefern. In Abbildung 2.1 wird der Entwicklungsablauf nach der ISO 26262 als V-Modell dargestellt, wobei die Einbringung der Testfälle hervorgehoben ist, da dies der Bereich ist, in dem die vorliegende Arbeit ansetzt.

2.3 Aktuelle Sicherheitsansätze

Shalev-Shwartz et al. [SSS17] vertreten die Auffassung, dass, ähnlich dem „Winter of AI“, bei dem der Hype um künstliche Intelligenz (engl. AI) in den 1980er Jahren abrupt abbrach, im Bereich des automatisierten Fahrens bald eine große Zeit der Enttäuschung beginnt, in der kein weiterer Fortschritt erzielt wird. Dies beruhe darauf, dass bei der aktuellen Forschung meist auf hundertprozentige Sicherheit geachtet werde, welche aber in bestimmten Szenarien nicht erreichbar sei. Daher wird eine Methode namens *Responsibility Sensitive Safety* (RSS) vorgeschlagen, wobei das Hauptaugenmerk auf dem Unfallverursacher liegt. Ziel ist es nun dafür zu sorgen, dass automatisierte Fahrzeuge nicht selbst für einen Unfall verantwortlich sind. Nach der Logik der Autoren kann so eine unfallfreie Zukunft ermöglicht werden, wenn ausschließlich automatisierte Fahrzeuge unterwegs sind, da für einen Unfall stets ein Verantwortlicher existiert.

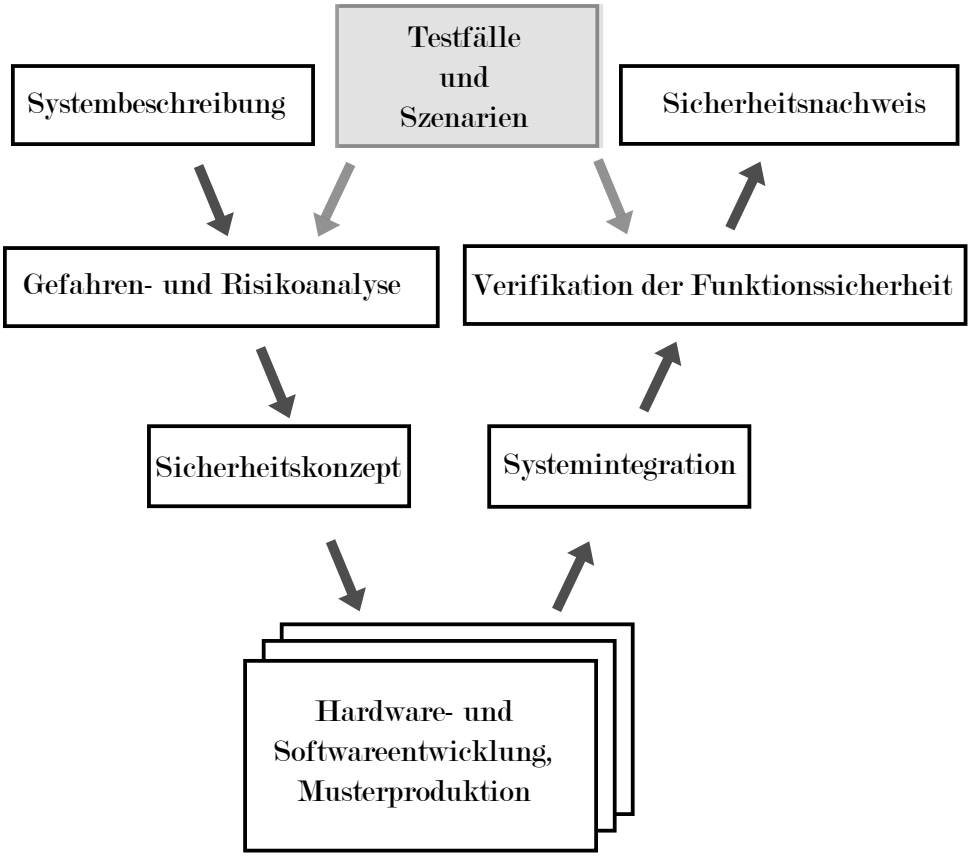

Abbildung 2.1: Teilbereiche und Ablauf bei der Systementwicklung nach der ISO 26262 als V-Modell. Die Schritte, bei denen Testfälle benötigt werden, sind zusätzlich angezeigt.

In der Luftfahrt ist eine ausführliche und tiefgreifende Absicherungspraxis seit Langem etabliert, nicht nur für die Produktion und Entwicklung neuer Flugzeuge, sondern auch für den späteren Betrieb. Kuchar und Yang [KY00; KY97] haben detaillierte Untersuchungen über verwendete Luftfahrtmodelle durchgeführt. Hierbei lag das Hauptaugenmerk auf der Modellkategorisierung. Unter anderem wurden diese nach den auftretenden Zustandsparametern oder der Prädiktionsmethode eingeteilt. Nach eigenen Aussagen ist es jedoch nötig, bei zukünftigen Modellen zusätzliche wichtige Aspekte für die Erkennung und Lösung von Konflikten in der Luftfahrt zu berücksichtigen. Genannt werden beispielsweise noch nicht betrachtete Unsicherheitsfaktoren, das gleichzeitige Auftreten mehrerer Konflikte, Anforderungen an die Rechenzeit und Implementierung, sowie Degradation oder Ausfall der Systeme und Anforderungen für die Verifizierung und Zertifizierung. Darüber hinaus existieren in der modernen Luftfahrt durch die hohe Flugzeugdichte noch andere sicherheitsrelevante Aspekte, welche Bestandteil aktueller Forschung sind, wie die von Flugzeugen erzeugten Wirbelschleppen [Gue15; Smi11]. Auch die mentale Belastung der Personen in der Flugverkehrskontrolle ist Teil der Forschung [LSNM07], da nicht ausschließlich der Pilot eines Flugzeugs für die Sicherheit zuständig ist, sondern auch die Flugverkehrskontrolle für den überwachten Luftraum. Durch die Luftüberwachung unterscheidet sich der Luftsektor grundsätzlich vom Individualverkehr auf der Straße.

2.4 Fahrzeug- und Verkehrsmodelle

Für die Modellierung von Fahrzeugen, anderen Verkehrsteilnehmern und des ganzen Verkehrs existieren unterschiedliche Modelle, wovon die gängigsten im Folgenden vorgestellt werden. Für eine detaillierte Übersicht über Modelle unterschiedlicher Komplexität wird auf [Unt13] verwiesen.

Ein weit verbreitetes Fahrzeugmodell ist das lineare Einspurmodell von Riekert und Schunk [RS41]. Hierbei handelt es sich um die Vereinfachung eines typischen PKW mit vier Rädern auf zwei Räder, eins mittig auf der jeweiligen Achse. Detaillierte Untersuchungen und Vergleiche mit anderen Einspurmodellen finden sich bei Schramm et al. [SHB10; SHB14]. Das Einspurmodell ist eines der einfachsten Modelle zur Erklärung und Modellierung der Fahrdynamik.

Bando et al. [BHN+95] stellen zwei verschiedene Fahrermodelle vor, ein *einfaches* und ein *realistisches* Modell, das durch Geschwindigkeitsanpassungen stets einen Abstand zum vorausfahrenden Fahrzeug hält. Darauf aufbauend wird von Treiber et al. [THH00] das *Intelligent Driver Model* (IDM) entworfen, das durch Vorgabe einer optimalen Beschleunigung stets eine kollisionsfreie Folgefahrt garantiert. Die

Parameter dieses Modells sind zusätzlich spezifisch für einzelne Fahrer [HSD17]. Da die Modelle für eine kollisionsfreie und realistische Verkehrssimulation entworfen wurden, können damit zwar sehr gut Stauverhalten untersucht werden, jedoch keine direkte Aussage über Kollisionswahrscheinlichkeiten getroffen werden. Als Weiterentwicklung des IDM ist das *Foresighted Driver Model* (FDM) [EDK15], welches eine Risikoabschätzung für die geplante Trajektorie vornimmt und dadurch möglichst risikoarm fährt.

Eine weitere Möglichkeit der Bewegungsmodellierung ist die Darstellung über ein kinematisches Punktmodell. Hierbei wird das Fahrzeug als Punkt angenommen und die Bewegung ausschließlich durch die Beschleunigungswerte bestimmt. Dieses Modell nutzt die mathematische Beschreibung von Beschleunigung, Geschwindigkeit und Position ohne auf die in der Realität dafür verantwortlichen Kräfte einzugehen. Dies ist der Unterschied zu dynamischen Modellen, die diese Kräfte mit modellieren.

Für die Simulation ganzer Straßennetze und Verkehrsströme kann die Simulationsumgebung *Simulation of Urban MObility* (SUMO) verwendet werden [BBEK11; GOC+15; KEBB12].

2.5 Ansätze zur Trajektoriengenerierung

Sowohl in der Robotik als auch im Bereich des automatisierten Fahrens werden Trajektorien benötigt, welche das Fahrzeug von Position A nach Position B überführen. Voraussetzung ist hierfür, dass Start- und Zielpunkt bekannt sind und auch die zu beachtenden Hindernisse korrekt vorliegen. Wird die reine Strecke zwischen den Punkten ohne zeitliche Information und Geschwindigkeitsinformation benötigt, spricht man von Pfadplanung, wobei beide Begriffe teilweise auch synonym zueinander verwendet werden. In [LaV06] beinhaltet die Pfadplanung auch die zeitliche Abfolge der Aktionen. Dabei werden nicht ausschließlich Fahrzeuge betrachtet, sondern die Problemstellungen beinhalten auch die Positionierung von Roboterarmen, das Bewegen von Objekten in engen Gängen und das optimale Absuchen von Höhlen.

Die schnelle Pfadplanung in einem Raum mit Hindernissen kann mit einem *Rapidly-exploring Random Tree* (RRT) durchgeführt werden [GSB14]. Weitere Verfahren zur Trajektorienplanung werden unter anderem in [LAB+11; WZKT10] vorgestellt.

2.6 Sicherheitsmaße und Risikobewertung

Eine bekannte und bewährte Methode, Gefahr zwischen zwei Fahrzeugen zu messen, ist die *Time-to-Collision* (TTC) von Hayward [Hay72]. Hierbei wird die voraussichtliche Zeit bis zu einer Kollision zweier Fahrzeuge berechnet. Dabei wird für jedes Fahrzeug eine feste, zukünftige Trajektorie angenommen und ausgewertet, wobei im einfachsten Fall für beide Fahrzeuge eine konstante Geschwindigkeit und Gierrate angenommen wird. Für Fahrzeuge, die sich nicht auf Kollisionskurs befinden, wächst die TTC ins unendliche, und für beliebig nahe Vorbeifahrten und Kollisionen geht die TTC gegen Null. Unter einer TTC von 0,5 s kann man von einer Kollision ausgehen [Hay72].

Da die Berechnung der TTC auf Grund ihrer Einfachheit für komplexe Szenarien ungenau wird, gibt es darauf aufbauend mehrere Bewertungsmethoden für das Risiko einer Verkehrssituation, wie die *Time-to-Brake* (TTB) von Hillenbrand [HKS05] oder die *Worst-Time-to-Collision* (WTTC) von Wachenfeld [WJWW16]. Diese Ansätze werden allgemein als *Time-to-X* (TTX) bezeichnet. Eine ausführliche Übersicht findet sich bei Junietz [JSW17].

Damerow und Eggert [DE14; DE15a; DE15b] stellen das Verfahren der prädiktiven Risikokarte (*predictive risk map*) vor, bei dem durch den Vergleich der geplanten Ego-Trajektorie mit der, mit konstanter Geschwindigkeit, prädizierten Trajektorie eines anderen Fahrzeugs eine Risikoabschätzung gemacht wird. Das Verfahren ermöglicht es, zu einer gegebenen Situation stets eine sichere und kollisionsfreie Trajektorie für das Ego-Fahrzeug zu finden, solange diese existiert.

Durch die Einführung von *reachable sets* (erreichbare Bereiche) können geplante Trajektorien auf ihre Kollisionsfreiheit überprüft werden [AD12; Alt10; ASB09]. Diese Methode liefert ein realistisches Ergebnis und ist für die Bewertung einzelner Situationen ausgelegt.

In [BBK04; BBK05] wird ein Verfahren vorgestellt, um unter Berücksichtigung aller anderen Objekte einen sicheren Pfad durch eine Szene zu erhalten. Hierbei werden einem Objekt durch eine Monte-Carlo (MC)-Methode alle möglichen Trajektorien zugeordnet und nach ihrer Kollisionsfreiheit bewertet. Anschließend wird die Wahrscheinlichkeit berechnet, dass sich alle beobachteten Objekte sicher, d.h. kollisionsfrei, bewegen können.

Aufbauend darauf wird in [EP08] ein Verfahren entwickelt, was zusätzlich berücksichtigt, dass Fahrer typischerweise Kollisionen vermeiden. Dafür werden zwei mögliche zukünftige Entwicklungen berücksichtigt, eine bei der das andere Fahrzeug versucht dem Ego-Fahrzeug auszuweichen, und eine bei der das Ego-Fahrzeug übersehen oder

nicht wahrgenommen wird. Die Gewichtung der beiden berechneten Entwicklungen geschieht über die Berücksichtigung der paarweisen Sichtbarkeit der Fahrzeuge. Um jedes Fahrzeug werden dafür Bereiche gelegt, in denen es mit einer unterschiedlichen Wahrscheinlichkeit ein anderes Fahrzeug wahrnimmt. Die verwendeten Wahrnehmungswerte in der Arbeit werden sinnvoll gewählt, jedoch nicht experimentell ermittelt.

Kapitel 3

Grundlagen

Im folgenden Kapitel wird kurz auf die verwendeten Begriffe, Methoden und Verfahren eingegangen. Die Begriffe Situation und Episode werden für diese Arbeit definiert, um sprachliche Präzision zu ermöglichen. Das für die Bewertung der Situationen benötigte Kritikalitätsmaß wird erläutert und die Konstrukte des Episoden- und Situationsraums werden vorgestellt. Diese Definitionen wurden im Rahmen dieser Arbeit entwickelt und teilweise in [SKPD16] veröffentlicht. Zusätzlich werden verwendete, bereits in der Literatur bekannte, Verfahren aufgeführt und kurz vorgestellt. Hierbei handelt es sich um die für die Trajektorienrepräsentation verwendete Polynomapproximation mittels Tschebyschow Polynomen und um die für die Episodengenerierung verwendete MC-Methode. Diese werden in Kapitel 4 für die Erstellung der verwendeten Datensätze benötigt. Zusätzlich werden die theoretischen Grundlagen für das Verfahren des *Gaussian Process Latent Variable Model* (GPLVM) und der *Support Vector Machine* (SVM) angeführt, die in Kapitel 5 für die Auswertung der Datensätze benötigt werden. Diese Ergebnisse wurden teilweise in [SD18] veröffentlicht.

3.1 Situation

Mit einer Situation ist im Rahmen der Arbeit stets eine Momentaufnahme der betrachteten Fahrzeuge gemeint. Zunächst wird die Anzahl der Fahrzeuge definiert, welche in einer Situation berücksichtigt werden, anschließend erhalten diese individuelle Eigenschaften. Ein Hauptaugenmerk bei der Erstellung der Situationsparameter ist, die gesamte Darstellung einer Situation so einfach wie möglich zu gestalten und dennoch eine möglichst große Vielfältigkeit zu bewahren. Daher wird in dieser Arbeit stets eine zweidimensionale Darstellung aus der Vogelperspektive verwendet, da ausschließlich Interaktionen zwischen Fahrzeugen auf einer Ebene betrachtet werden. Zusätzlich liegt über den Inhalt einer Situation stets vollständige Information vor

und die Anzahl der Fahrzeuge einer Situation ist unveränderlich. Abbildung 3.1 zeigt eine Situation mit zwei Fahrzeugen.

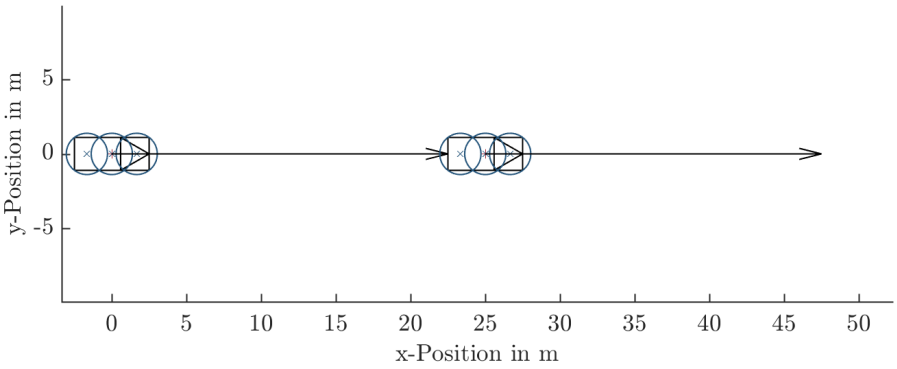

Abbildung 3.1: In dieser Situation werden zwei Fahrzeuge betrachtet. Die Startpositionen und -geschwindigkeiten werden durch die Pfeile dargestellt. Die Umrisse werden durch Rechtecke und Kreise gezeigt.

Jedes Fahrzeug besitzt einen Zustand, eine Geometrie und Beschränkungen, welche für verschiedenen Fahrzeuge unterschiedlich sein können. Dies ermöglicht die Modellierung von Fahrzeugen mit unterschiedlichen Fahreigenschaften, wie beispielsweise große und träge Fahrzeuge, aber auch kleine und wendige Fahrzeuge. Diese Anforderungen werden folgendermaßen mathematisch umgesetzt:

$$\mathcal{S} \in \mathfrak{S} \text{ mit} \tag{3.1}$$

$$\mathcal{S} = \{N, \mathfrak{Z}, \mathfrak{G}, \mathfrak{L}\} \tag{3.2}$$

Hierbei bezeichnet die Situation $\mathcal{S}$ aus dem Situationsraum $\mathfrak{S}$ die Menge aller Parameter in einer Situation. Davon ist N die Anzahl der Fahrzeuge, $\mathfrak{Z}$ deren Zustand, $\mathfrak{G}$ deren Geometrie und $\mathfrak{L}$ deren Beschränkungen.

Die Parametermengen $\mathfrak{Z}$, $\mathfrak{G}$ und $\mathfrak{L}$ enthalten für jedes Fahrzeug individuell festgelegte Werte und sind wie folgt aufgebaut:

$$\mathfrak{Z} = \begin{pmatrix} z_0 \\ \vdots \\ z_{N-1} \end{pmatrix}, \qquad z_i = (x_i, y_i, v_{i,x}, v_{i,y}, a_{i,x}, a_{i,y}, \varphi_i) \tag{3.3}$$

$$\mathfrak{G} = \begin{pmatrix} g_0 \\ \vdots \\ g_{N-1} \end{pmatrix}, \qquad g_i = (l_i, b_i, r_i, k_i) \tag{3.4}$$

$$\mathfrak{L} = \begin{pmatrix} \mathfrak{l}_0 \\ \vdots \\ \mathfrak{l}_{N-1} \end{pmatrix}, \qquad \mathfrak{l}_i = (a_{i,x/y,\min/\max}, v_{i,x/y,min/max}, a_{i,kamm}) \tag{3.5}$$

Die Erläuterungen der Parameter aus Gleichungen 3.3 bis 3.5 finden sich in Tabelle 3.1. Die Indices x und y beziehen sich auf die Richtung des jeweiligen Parameters.

Der Referenzpunkt wird hier immer auf der Längsachse des Fahrzeugs angenommen und r_i bezeichnet den Abstand zur Fahrzeugrückseite anteilig zur Gesamtlänge. Dieser kann beliebig sein, wird in der vorliegenden Arbeit jedoch stets auf 0,5 gesetzt, wodurch sich der Referenzpunkt mittig im Fahrzeug befindet. Die für die Kreisapproximation in Abschnitt 4.3.2 benötigte Kreisanzahl k_i ist ebenso pro Fahrzeug frei wählbar. Bei der Erstellung und Auswertung der Daten wird $k_i = 3$ verwendet, wodurch Pkw effizient dargestellt werden können. Für andere Fahrzeugklassen eignen sich andere Werte.

Tabelle 3.1: Übersicht der 20 fahrzeugspezifischen Parameter einer Situation. Der Index i bezeichnet das Fahrzeug i

x_i, y_i	Position des Fahrzeugs (Referenzpunkt) im ortsfesten Koordinatensystem mit Ursprung (x_0, y_0)
$v_{i,x}$, $v_{i,y}$	Geschwindigkeit des Fahrzeugs
$a_{i,x}$, $a_{i,y}$	Beschleunigung des Fahrzeugs
φ_i	Winkel des Fahrzeugs relativ zur x-Achse
l_i, b_i	Länge und Breite des Fahrzeugs
k_i	Anzahl der Approximationskreise
r_i	Abstand zur Fahzeugrückseite des Referenzpunkts
$a_{i,x/y,\min/\max}$	Minimal- und Maximalbeschleunigung
$v_{i,x/y,min/max}$	Minimal- und Maximalgeschwindigkeit
$a_{i,kamm}$	maximale Gesamtbeschleunigung

Durch diese Definition einer Situation ist eine vielfältige Modellierbarkeit gegeben. Auch wenn in dieser Arbeit ausschließlich Pkw als Verkehrsteilnehmer berücksichtigt werden, sind andere Objekte darstellbar. Diese würden über geeignete Geometrien und Beschränkungen generiert. Durch die Festlegung der Objektanzahl N besitzt jede Situation $20 \cdot N$ viele Parameter in der oben vorgestellten Version. Später wird zur Reduktion der Komplexität eine verringerte Parameteranzahl verwendet.

Nach der Definition einer Situation ergibt sich die Notwendigkeit deren zeitlichen Verlauf zu beschreiben, da eine Situation stets eine Momentaufnahme darstellt.

3.2 Episode

Aufbauend auf einer gegebenen Ausgangssituation $\mathcal{S}$ nach Gleichung 3.1 beschreibt eine Episode einen möglichen zeitlichen Verlauf von $\mathcal{S}$. Dieser wird über die Menge der einzelnen Positionsverläufe der betrachteten Fahrzeuge beschrieben [SKPD16]. Eine Episode $\mathcal{E}_\mathcal{S}$ wird dargestellt als

$$\mathcal{E}_\mathcal{S} = \{\zeta_0, \ldots, \zeta_{N-1}\} \tag{3.6}$$

Hierbei bezeichnet ζ_i die in der Episode $\mathcal{E}_\mathcal{S}$ gefahrene Trajektorie des Fahrzeugs i. Mit $\mathcal{E}_\mathcal{S}$ wird eine Episode zu einer bestimmten Situation bezeichnet, die Indizierung mit $\mathcal{S}$ kann bei Eindeutigkeit ausgelassen werden.

Theoretisch können aus jeder Situation unendlich viele Episoden entstehen. In der Realität ist die beobachtete Anfahrt eines Fahrzeugs die einzig eingetretene Episode, die aus der Situation des stehenden Fahrzeugs entstanden ist. Die genaue Ausprägung dieser Fahrt ließe sich jedoch beliebig variieren, wodurch mit jeder Variation eine andere Episode generiert werden würde. Zur Darstellung der Trajektorien ζ_i wird für jedes Fahrzeug eine Funktion f benötigt, welche dessen Ort zu einem bestimmten Zeitpunkt festlegt.

$$\zeta_i(t) = \begin{pmatrix} f_{i,x}(t) \\ f_{i,y}(t) \end{pmatrix} \tag{3.7}$$

Hier werden die einzelnen Trajektorien in ihren x- und y-Anteil aufgeteilt, was eine leichtere Verarbeitung und die direkte Ableitung nach der Zeit in Geschwindigkeit und Beschleunigung ermöglicht. Die konkrete Wahl der Funktion f ist unabhängig vom Konzept einer Episode, f wird bei der Modellierung der Episoden in Kapitel 4 festgelegt. Die Grundlage für die Modellierung stellen Tschebyschow Polynome dar, welche in Abschnitt 3.6 erläutert werden. Die Episoden, welche sich aus einer Situation aufbauen lassen, bilden einen Episodenraum.

3.3 Episodenraum

Die Menge aller berechneten Episoden $\mathcal{E}_\mathcal{S}$ zu einer Situation $\mathcal{S}$ wird mit $\mathfrak{E}_\mathcal{S}$ bezeichnet. Die Anzahl der betrachteten Episoden in einem Episodenraum wird mit $|\mathfrak{E}_\mathcal{S}|$ bezeichnet.

Durch die hier gewählte Hierarchie, dass Episoden auf Situationen aufbauen, gilt eine konkrete Episode ausschließlich für eine bestimmte Situation. Eine Episode für eine Situation mit zwei Fahrzeugen kann nicht für eine Situation mit drei Fahrzeugen verwendet werden. Somit besitzt jede Situation $\mathcal{S}$ auch einen eigenen Episodenraum $\mathfrak{E}_\mathcal{S}$ bzw. $\mathfrak{E}$, wenn die verwendete Situation eindeutig ist. Durch die Wahl einer geeigneten Repräsentation kann allerdings erreicht werden, dass Episoden in bestimmten Fällen zwischen verschiedenen Situationen getauscht werden können. Dadurch ist es möglich, einen allgemeinen Episodenraum aufzuspannen, der nur von den gewählten Parametern der Episodendarstellung abhängt. Wodurch auch ein Vergleich zwischen verschiedenen Episodenräumen möglich wäre. Allerdings kann die Aussage über die Kritikalität einer Episode, welche stark von den Situationsparametern abhängt, nicht auf andere Situationen übertragen werden. Wird nun die Kritikalität, als wichtige Eigenschaft einer Episode, mit in den Raum aufgenommen, verliert dieser die Gültigkeit für verschiedene Situationen und jede neue Situation spannt einen neuen Episodenraum auf. Daher wurde ein direkter Vergleich verschiedener Episodenräumen sowie der Transfer eines Episodenraums auf eine andere Situation in der vorliegenden Arbeit nicht betrachtet.

Die Hauptfunktion der Episodenräume in dieser Arbeit liegt in ihrer Funktion als Repräsentation einer Menge an Episoden für eine bestimmte Situation. Diese ist wiederum selbst Teil des Situationsraums.

3.4 Situationsraum

Analog zum Episodenraum $\mathfrak{E}$, ist mit dem Situationsraum $\mathfrak{S}$ derjenige Raum definiert, in dem alle Situationen mit einem gewissen Parametersatz liegen. Bei den vielfältigen Modellierungsmöglichkeiten einer Situation ist der wichtigste Parameter die Anzahl der Fahrzeuge, da diese den größten Einfluss auf die Komplexität der Situation, der daraus resultierenden Episoden und des Rechenaufwands hat. Die Anzahl der betrachteten Parameter legt zugleich die Dimension des Situationsraums fest, bei N Fahrzeugen sind dies bis zu $20 \cdot N$ Parameter. Allerdings kann eine Reduktion der Parameter durchgeführt werden, wodurch eine niedrigere Dimensionierung erzielt wird. Hierfür werden unter anderem die Fahrzeuggeometrie und -beschränkungen für

alle Objekte identisch angenommen. Unterschiedlich große Fahrzeuge können Einfluss auf die Kritikalität einzelner Situationen haben, jedoch wird sich am Vorgehen der Auswertung und der Charakterisierung nichts ändern. Gleiches gilt für Fahrzeuge, welche unterschiedliche Beschränkungen bei Geschwindigkeit und Beschleunigung vorgegeben haben.

Jeder Punkt des Situationsraums definiert eine bestimmte Situation, welche durch die später aufgeführten Verfahren mit einer Kritikalität belegt werden kann. Durch die Bewertung aller[8] Situationen wird eine Bewertung des gesamten Situationsraums $\mathfrak{S}$ ermöglicht. Eine Zielstellung dieser Arbeit ist es daher, die Struktur des Situationsraums $\mathfrak{S}$ zu bestimmen und Rückschlüsse auf einzelne Situationen zu ziehen. Daraus sollen Empfehlungen für Testfälle und interessante Situationen abgeleitet werden, durch die Unterstützung bei der Absicherung von Fahrfunktionen geleistet wird.

3.5 Kritikalität

Durch die Einführung der Begriffe Situation und Episode ist der Grundstein für eine einheitliche Darstellung von Fahrzeugkonstellationen und deren zeitliche Abfolge gelegt. Im weiteren Verlauf bedarf es einer Auswertemethodik, um die Höhe des Risikos in der jeweiligen Situation und in einer der vielen zugehörigen Episoden zu erfassen. Zunächst muss jedoch eine Definition dieses Risikos erfolgen, welches bestimmt wie kritisch oder unkritisch eine Situation eingeschätzt wird. Dieses Risiko wird im Folgenden Kritikalität genannt und ist nicht gleichbedeutend mit der Definition von *Risiko* gemäß der ISO 26262. In der Literatur finden sich in diesem Zusammenhang Übersichten über verschiedene Ausprägungen, welche je nach Anwendungsfall andere Schwerpunkte legen [JSW17; LVL14].

Die TTC-Metrik ist eine der ersten, welche das Risiko einer Verkehrssituation bewerten [Hay72]. Für ihre Entwicklung wurden anhand von Videoaufnahmen händisch Positionen und Geschwindigkeiten von Fahrzeugen extrahiert. Aufbauend darauf wurde die Zeitspanne bis zur erwarteten Kollision abgeleitet, welche im unkritischen Fall beliebig groß werden kann und in einer kritischen Situation gegen Null strebt. In [Hay72] wurde eine Zeitspanne von etwa 0,5 s als unterste Grenze veranschlagt, ab der es sicher zu einer Kollision kommen wird.

In [WJWW16] wird eine Erweiterung dieser Metrik vorgestellt, bei der nicht nur die aktuellen Zustände der Fahrzeuge berücksichtigt werden, sondern auch die maximal möglichen Beschleunigungen gemäß des kammschen Kreises, die WTTC. Dabei

[8] Da überabzählbar viele Situationen existieren, wird stets eine endliche, jedoch ausreichend große Teilmenge untersucht, welche als Vertreter aller Situationen fungiert.

wird für jeden Zeitschritt die minimale und maximale Beschleunigung als mögliche Entwicklung angenommen. Damit wächst die Größe des möglichen Aufenthaltsbereichs eines Fahrzeugs mit der Zeit. Durch die Berechnung einer Überlappung der Aufenthaltsbereiche zweier Fahrzeuge kann der früheste Zeitpunkt einer Kollision berechnet werden. Wie bei der TTC bedeutet eine kleine WTTC, dass eine kritische Situation vorliegt. Da die WTTC die Schwere der Kollision nicht berücksichtigt, kann bei einem Einparkvorgang eine sehr geringe WTTC auftreten.

In der vorliegenden Arbeit wird durch eine ähnliche Überlegung die Kritikalität definiert: Wenn in einer Episode eine Kollision auftritt, ist diese kritisch, wenn nicht, ist sie unkritisch [SKPD16]. Da jede Episode eine spezifische Trajektorie für jedes Fahrzeug vorsieht, kann eine binäre Aussage über das Auftreten einer Kollision getätigt werden. Über die Anzahl der Episoden einer Situation kann dann das Verhältnis der kritischen Episoden zur Gesamtzahl der betrachteten Episoden berechnet werden, welches als Kritikalitätsmaß für die Bewertung der Situation dient. Die Kritikalität $\boldsymbol{\Upsilon}$ berechnet sich aus den Mächtigkeiten der Menge $\boldsymbol{\gamma}$ der kritischen Episoden und der Menge $\boldsymbol{\gamma}\neg$ der unkritischen Episoden wie folgt:

$$\boldsymbol{\Upsilon} = \frac{|\boldsymbol{\gamma}|}{|\boldsymbol{\gamma}| + |\boldsymbol{\gamma}\neg|} \tag{3.8}$$

Hieraus folgt, dass eine Situation, für die keine unkritische Episode gefunden wird die Kritikalität 1 erhält, und eine Situation, für die keine kritische Episode gefunden wird die Kritikalität 0. Im Allgemeinen hängt dieser Wert auch von der Anzahl an generierten Episoden ab und ist erst nach einer großen Anzahl an Episoden aussagekräftig. Falls im Kontext nötig, wird die Kritikalität $\boldsymbol{\Upsilon}$ für die Situation $\mathcal{S}$ basierend auf $|\mathfrak{E}_\mathcal{S}|$ generierten Episoden mit $\boldsymbol{\Upsilon}_\mathcal{S}^{|\mathfrak{E}_\mathcal{S}|}$ bezeichnet.

Das hier verwendete Kritikalitätsmaß ist darauf ausgelegt, möglichst schnell berechenbar zu sein, da eine große Anzahl an Situationen damit bewertet werden soll. Dadurch bedingt soll eine um mehrere Größenordnungen höhere Anzahl an Episoden bewertet werden, weshalb auch jede einzelne davon möglichst schnell zu bewerten ist. Daher wird hier auf die reine Anwesenheit von Kollisionen im betrachteten Zeithorizont getestet.

Mögliche Erweiterungen für detailliertere Untersuchungen wären das Einbeziehen des Kollisionszeitpunktes, der Art der Kollision oder auch deren Schwere. Folgende Überlegungen und Anpassungen müssten dafür durchgeführt werden:

Da die Episoden zufällig gezogen werden, sind auch mehrere Kollisionen innerhalb eines Zeithorizontes nicht ausgeschlossen. Daher müsste zur Einbeziehung des Zeitpunktes stets die erste Kollision gefunden werden. Bei der hier vorgestellten Methode genügt hingegen der Nachweis einer beliebigen Kollision. Jede weitere Kollision träte

in der Realität nach einer ersten nicht auf, da die beteiligten Fahrzeuge eine abrupte Trajektorienänderung erführen. Diese wird in der Trajektoriengenerierung jedoch nicht berücksichtigt, da diese unabhängig für jedes Fahrzeug erfolgt. Zur Berücksichtigung der Art der Kollision müsste ebenso zunächst garantiert die erste Kollision gefunden werden und diese anschließend auf die Fahrzeugkonstellation hin überprüft werden. Dazu wäre noch eine Logik über die Bewertung dieser Konstellationen vonnöten, welche beispielsweise ein seitliches Touchieren oder ein rückseitiges Auffahren unterscheidet. Bei der Berücksichtigung der Schadensschwere kann die Relativgeschwindigkeit verwendet werden, die sich in Abhängigkeit zur Fahrzeugkonstellation berechnen lässt. Diese Auswertungen sind sehr interessant bei der Untersuchung einzelner Episoden, erhöhen die Auswertungskomplexität jedoch enorm. In diesem Kontext wird dieser Detailgrad jedoch nicht benötigt, da hier die Aussagen zur Kritikalität über eine statistische Anzahl an Episoden gemacht werden und nicht über einzelne, ausgewählte Episoden.

3.6 Polynomapproximation und Tschebyschow Polynome

Für die Modellierung der Episoden wird eine geeignete Funktion benötigt. Diese beruht auf der Darstellung der Trajektorien über Polynome, welche die Beschleunigungen beschreiben. In [BM09] werden mehrere Varianten vorgestellt, wie Trajektorien über Polynome dargestellt werden können.

Da für die Auswertung einer Situation unter Umständen sehr viele Episoden generiert und verarbeitet werden müssen, sollte die Generierung und Speicherung einer Episode effizient und schnell erfolgen können. Eine einzelne Episode besteht aus den Trajektorien der beinhalteten Fahrzeuge, welche sich unterschiedlich darstellen lassen. Eine Speicherung des Zustands zu jedem Zeitschritt wäre eine Möglichkeit, benötigte allerdings eine relativ große Datenmenge. Möchte man mindestens die Position (x_i, y_i) und die Geschwindigkeit $(v_{i,x}, v_{i,y})$ mit 20 Zeitschritten in der Sekunde speichern, würden bei einer zehn Sekunden langen Trajektorie 800 Werte benötigt. Diese Modellierung ist dann auch fest mit der Abtastrate verbunden.

Zusätzlich müssten auch diese aufeinanderfolgenden Zustände zunächst durch ein Modell generiert werden. Hierzu kann eines der Verfahren aus Abschnitt 2.4 zur Anwendung kommen. Allerdings benötigen auch diese Modelle zur Berechnung eines weiteren Zeitschritts entsprechende Eingaben. Die tatsächlichen Steuergrößen, je nach Modell beispielsweise die Beschleunigung und der Lenkwinkel, müssten dann für jeden Zeitschritt vorgegeben werden. Dadurch würde für eine automatisierte Generierung

eine Funktion benötigt, welche diese Steuergrößen für jeden Zeitschritt für die gesamte Episode ermittelt. Dieses Vorgehen hätte einen immensen Rechenaufwand zur Folge.

Daher wird hier ein direkter Weg gewählt, um die gesamte Episode, ohne Zwischenschritt über Modellberechnungen, generieren zu können: die Trajektorien werden durch Polynome dargestellt, deren Koeffizienten zufällig gewählt werden. Somit brauchen nur diese Polynomkoeffizienten gespeichert werden, um eine vollständige Episode zu definieren. Zusätzlich sind die Trajektorien für jeden Zeitpunkt definiert und können daher beliebig genau untersucht werden. Ein weiterer Vorteil bei der Verwendung von Polynomen ist deren Differenzier- und Integrierbarkeit, wodurch Position, Geschwindigkeit und Beschleunigung ohne großen Rechenaufwand ineinander umgerechnet werden können.

Die nach Tschebyschow benannte Klasse der Tschebyschow-Polynome hat sich dabei als besonders geeignet erwiesen und kommt erstmals in seiner Arbeit von 1854 vor [Che54]. Das n-te Tschebyschow-Polynom T_n ist definiert als

$$T_n(x) = \cos\left(n \cdot \arccos(x)\right), \qquad x \in [-1, 1]. \tag{3.9}$$

Alternativ existiert die folgende rekursive Darstellung[9]:

$$T_0(x) = 1 \tag{3.10}$$
$$T_1(x) = x \tag{3.11}$$
$$T_{n+1}(x) = 2x \cdot T_n(x) - T_{n-1}(x) \tag{3.12}$$

Die nächsten drei Polynome sind folglich:

$$T_2(x) = 2x^2 - 1 \tag{3.13}$$
$$T_3(x) = 4x^3 - 3x \tag{3.14}$$
$$T_4(x) = 8x^4 - 8x^2 + 1 \tag{3.15}$$

In Abbildung 3.2 sind die Tschebyschow-Polynome $T_0(x)$ bis $T_4(x)$ im Bereich $x \in [-1, 1]$ dargestellt. Hier werden die Eigenschaften dieser Polynome ersichtlich. Die Polynome $T_i(x), i > 0$ nehmen alle Werte im Intervall $[-1, 1]$ an und haben i Nullstellen.

[9] Die Tschebychow-Koeffizienten bilden die OEIS Folge A028297, `https://oeis.org/A028297`, abgerufen am 28. Februar 2020

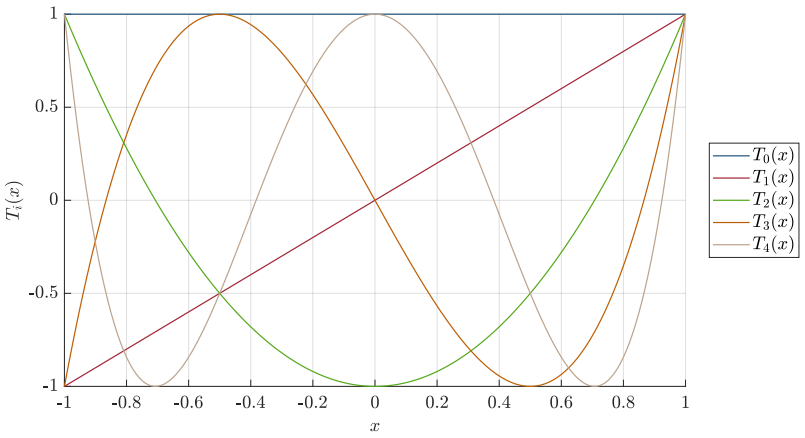

Abbildung 3.2: Illustration der Tschebyschow-Polynome $T_0(x)$ bis $T_4(x)$.

Zur Darstellung beliebiger Funktionen wird eine gewichtete Summe aus den Tschebyschow-Polynomen gebildet:

$$\tilde{f}(x) = \sum_{j=0}^{N-1} c_j T_j(x). \tag{3.16}$$

Die Koeffizienten c_j sind dabei die verlaufsbestimmenden Parameter. Der für die spätere Anwendung gewünschte Definitionsbereich liegt nicht notwendigerweise bei $[-1, 1]$, dadurch wird eine Transformation von $\hat{x} \in [a, b]$ nach $x \in [-1, 1]$ mittels

$$x = \frac{2\hat{x} - (a + b)}{b - a} \tag{3.17}$$

notwendig.

Diese Darstellung von Polynomen über Tschebyschow-Polynome wird in Kapitel 4 bei der konkreten Trajektoriengenerierung verwendet.

Alternativ ist es möglich Trajektorien über Stützstellen in gewissen Zeitabständen darzustellen, wie in [TSP+18; ZBDS14; ZBS+14] beschrieben. Eine stückweise Repräsentation über Splines ist ebenso realisierbar, was in [EM01; Jol76] gezeigt wird.

3.7 Monte-Carlo-Methode

Für die Betrachtung ein- oder mehrdimensionaler Datenräume werden diese an unterschiedlichen Stellen ausgewertet und darauf aufbauend eine Struktur abgeleitet oder eine Funktion approximiert. Diese Auswertestellen können äquidistant verteilt werden, wobei durch eine höhere Dichte der Auswertestellen eine genauere Abtastung ermöglicht wird. Durch diese Methode kann sichergestellt werden, dass der gesamte Raum in den gegebenen Intervallen gleichmäßig und bis an die Ränder untersucht wird. Allerdings stößt diese Methode auch schnell an ihre Grenzen. Zum einen, ist durch die feste Wahl der Auswertestellen nicht gesichert, dass interessante Datenbereiche erfasst werden, zum anderen steigt mit der Anzahl der Dimensionen der Auswerteaufwand exponentiell an[10].

Eine effizientere Methode bildet hier die MC-Methode, bei der die zu untersuchenden Datenpunkte nicht fest vorgegeben, sondern zufällig gewählt werden. Die Beschreibung der Methodik führt auf die 1940er Jahre zurück [Met87]. Als anschauliches Beispiel lässt sich die Näherung der Kreiszahl π anführen. Hierbei werden im Einheitsquadrat zufällig Punkte gezogen und bewertet ob sie innerhalb oder außerhalb des Einheitskreises liegen. Das Verhältnis der Punkte innerhalb des Einheitskreises zu der Gesamtzahl der gezogenen Punkte, nähert sich mit steigender Punktezahl $\frac{\pi}{4}$ an. In Abbildung 3.3 ist der Vergleich zwischen äquidistanter Rasterung und der MC-Methode dargestellt.

Hierbei ist zu beachten, dass bei mehrmaliger Durchführung der beiden Verfahren, der Näherungswert für π bei äquidistanter Rasterung gleich bleibt, und bei der MC-Methode durch die zufällige Wahl der Punkte schwankt. In Abbildung 3.4 wird das Ergebnis des Verfahrens mit einer größeren Stichprobe gezeigt.

[10] Die zweite Eigenschaft wurde als „Fluch der Dimensionalität“ durch Richard Bellman 1957 eingeführt.

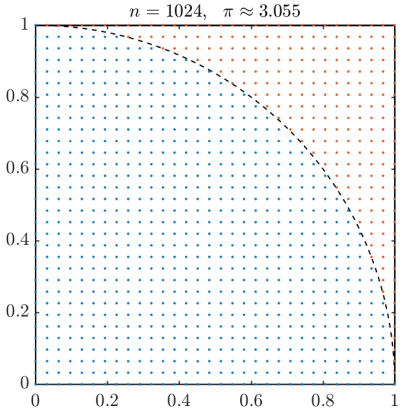

(a) Äquidistante Rasterung

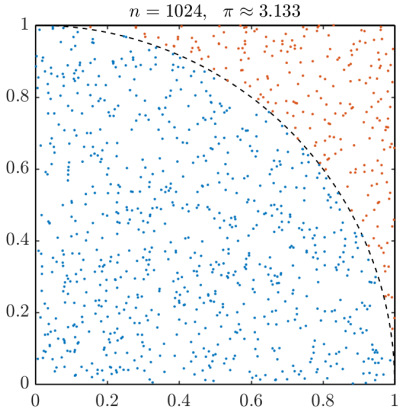

(b) Zufällige Wahl

Abbildung 3.3: Vergleich zwischen äquidistanter und zufälliger Rasterung des Datenbereichs zur Näherung von π.

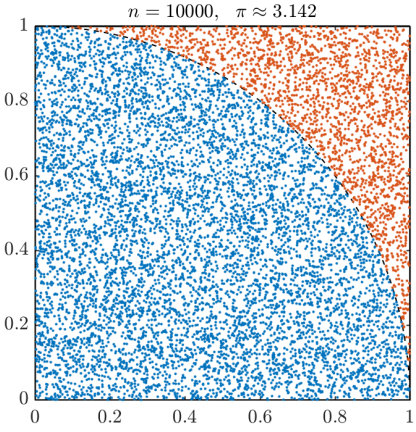

Abbildung 3.4: Näherung der Kreiszahl π durch das MC-Verfahren. Durch die Streuung von 10000 Punkten kann π auf zwei Nachkommastellen genau genähert werden.

3.8 *Gaussian Process Latent Variable Model*

Um Strukturen in Datensätzen sichtbar zu machen, kann es zunächst genügen, diese in einer niedrig-dimensionalen Darstellung zu visualisieren. Ein Verfahren, welches in der Literatur gut für hochdimensionale Datensätze funktioniert, ist das GPLVM. Dieses wird in [Law04; Law05] vorgestellt. Grundsätzlich kommt hierbei eine modifizierte Hauptkomponentenanalyse zum Einsatz, wobei der Datensatz bestmöglich in einen niedrig-dimensionalen latenten Raum eingebettet werden soll. Auch in jüngeren Veröffentlichungen [HZG$^+$16; Ras16] wird das Verfahren erfolgreich zur Datenvisualisierung und Dimensionsreduktion eingesetzt.

Für das GPLVM wird ein Datensatz $(\mathbb{X}, \mathbb{Y})$ mit

$$\mathbb{X} \in \mathbb{R}^{n \times d} \text{ und}$$
$$\mathbb{Y} \in \mathbb{Z}^n$$

als Eingabe verwendet, wobei jedem d-dimensionalen Datenpunkt $x_i \in \mathbb{X}$ eine Klasse $y_i \in \mathbb{Y}$ zugeordnet ist. Das Verfahren berechnet die Funktion $\Phi : \mathbb{X} \to \mathbb{P}$, welche die Eingangsdaten in den latenten Raum $\mathbb{P} \in \mathbb{R}^{n \times p}$ projiziert, mit $p \ll d$. Nach Durchführung des Verfahrens kann der Datensatz im latenten Raum untersucht werden. Als anschauliches Beispiel dient ein 12-dimensionaler Datensatz, welcher auch für die Auswertung in [Law04] verwendet wird. Dabei handelt es sich um Messdaten einer Ölpipeline. Die drei verschiedenen Klassen stellen die unterschiedlichen Phasen in der Pipeline dar: Öl, Wasser und Gas. Die Gesamtübersicht in Abbildung 3.5 stellt alle zwölf vorhandenen Dimensionen dar.

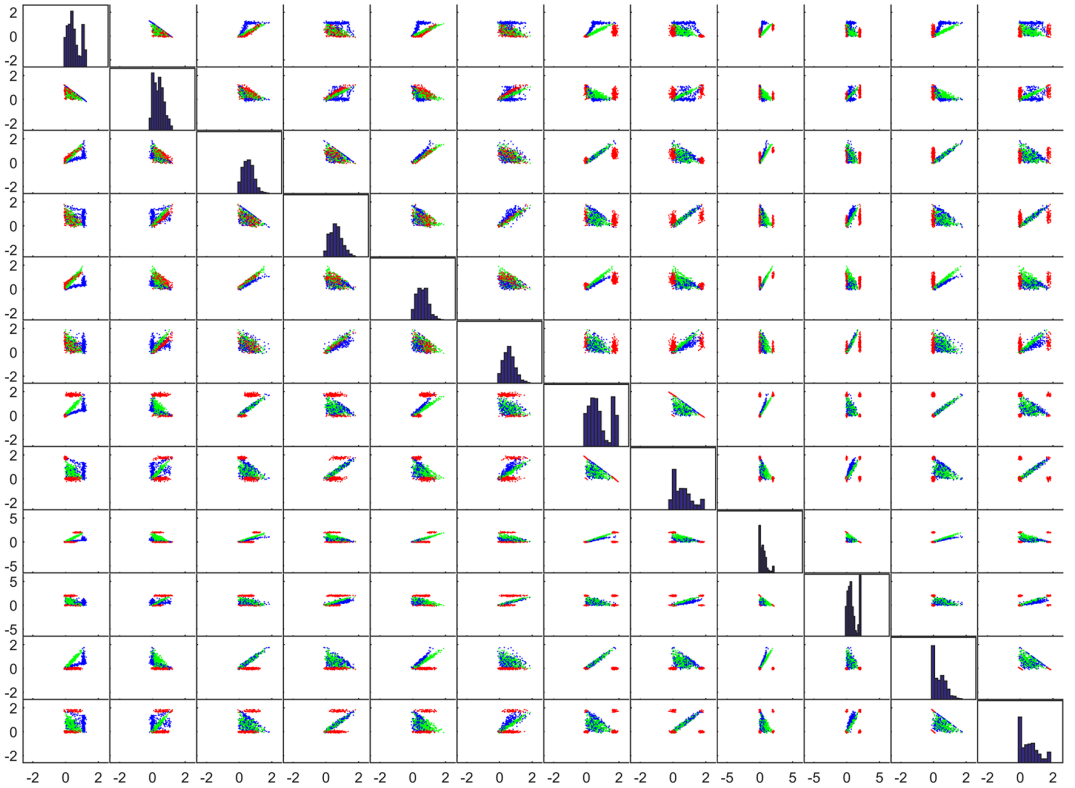

Abbildung 3.5: Abbildung aller 12 Dimensionen des Datensatzes. Die Diagonale zeigt die Häufigkeitsverteilung der einzelnen Parameter. Die anderen Einträge zeigen die paarweise Auftragung der Dimensionen übereinander

Diese Darstellung ist allerdings weder übersichtlich noch aussagekräftig. Daher werden in Abbildung 3.6 exemplarisch die Dimensionen 3 und 4 sowie 1 und 7 dargestellt.

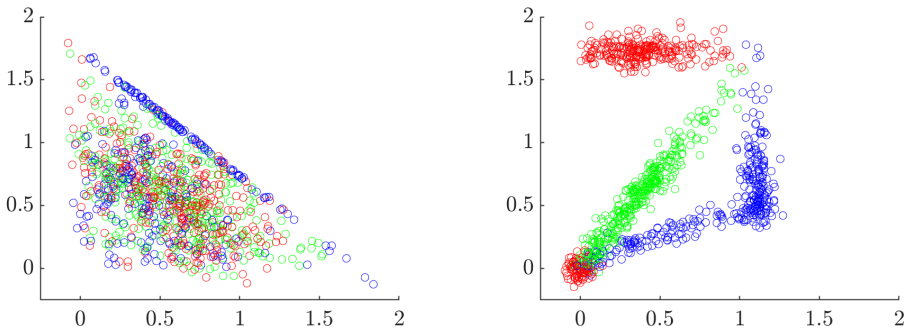

Abbildung 3.6: (a) Abbildung der Dimensionen 3 und 4 des Datensatzes. Hier ist nicht ersichtlich, wie die unterschiedlichen Klassen getrennt werden können. (b) Abbildung der Dimensionen 1 und 7 des Datensatzes. Hier bilden sich bereits Häufungen der einzelnen Klassen aus.

Links ist zu erkennen, dass sich aus dieser Ansicht keine Rückschlüsse auf die Trennbarkeit der einzelnen Klassen schließen lässt. Rechts zeigt sich, dass in diesen beiden Dimensionen bereits ein Muster in den Daten vorhanden ist.

Wird auf diesem 12D-Datensatz ein GPLVM trainiert, ergibt sich das 2D Ergebnis in Abbildung 3.7. Es ist zu erkennen, dass das Verfahren die Daten in verschiedene Cluster eingeteilt und in einen 2D-Raum eingebettet hat.

Bei Anwendung des GPLVM auf die Situationsdatensätze soll sich ein vergleichbares Ergebnis einstellen. Wenn sich verschiedene Situationscluster herausbilden, können diese in weiteren Schritten aufbereitet werden. Es soll beispielsweise möglich sein einen Repräsentanten eines Clusters zu bestimmen, oder weitere Situationen mit ähnlichen Eigenschaften zu generieren.

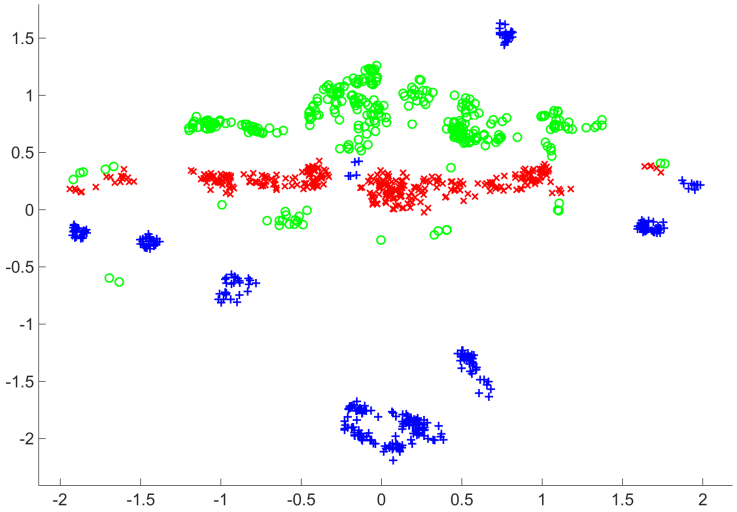

Abbildung 3.7: Darstellung des Ergebnisses des GPLVM. Das Verfahren konnte die Klassen in unterschiedliche Cluster aufteilen.

3.9 *Support Vector Machine*

Zur Klassifizierung mehrklassiger Datensätze gibt es verschiedenste Ansätze. Ein Beispiel ist die SVM (dt. Stützvektormaschine), deren Beschreibung aus dem Jahr 1992 stammt [BGV92], wobei diese Bezeichnung damals noch nicht verwendet wurde. Ausführliche und anschauliche Beschreibungen von SVMs finden sich in [Bis06; Bur98; PFTV07], an welche auch die folgende kurze Einführung angelehnt ist. Die Aufgabe einer SVM ist es, einen gegebenen Datensatz $(\mathbb{X}, \mathbb{Y})$ mit den Datenpunkten

$$\mathbb{X} = \{x_i \in \mathbb{R}^n \mid i = 1, \ldots, m\}$$

nach den zugehörigen Klassen $\mathbb{Y}$

$$\mathbb{Y} = \{y_i \in \{-1, 1\} \mid i = 1, \ldots, m\}$$

durch eine Hyperebene zu trennen. Diese Hypereben wird so gelegt, dass der minimale Abstand der Datenpunkte zu ihr maximiert wird. Diejenigen Datenpunkte, die am nächsten an dieser Hyperebene liegen, werden Stützvektoren genannt, da sie alleinig zur Definition der Hyperebene dienen, diese gewissermaßen *stützen*. Ist ein Datensatz durch eine Gerade linear trennbar, spricht man von einer linearen SVM. Ein Beispiel dafür befindet sich in Abbildung 3.8a. Dort ist die eine Klasse (rote Kreuze (**x**))

vollständig von der anderen Klasse (blaue Pluszeichen (+)) trennbar. Gelingt dies nicht, wird die Berechnung der Hyperebene in einem höherdimensionalen Raum durchgeführt, dafür werden die Datenpunkte über einen *Kernel* implizit in diesen Raum transformiert. Hierfür bietet sich der *Radial Basis Function* (RBF)-Kernel an, der in Abbildung 3.8b verwendet wird, um die kreisförmige, innere Klasse von der äußeren zu trennen. Die Hyperebene wird über den zugehörigen Normalenvektor $\mathbf{w}$ definiert, welcher unter der Bedingung

$$y_i(\langle \mathbf{w}, x_i \rangle + b) \geq 1, \ i = 1, \ldots, m \tag{3.18}$$

mit minimaler Norm berechnet wird [PFTV07]. Hierbei beschreibt b den Abstand des jeweiligen Punktes zu der Ebene. Über die Kernelfunktion

$$K_{ij} = K(x_i, x_j) = \langle \varphi(x_i), \varphi(x_j) \rangle \tag{3.19}$$

wird die Berechnung des Skalarprodukts im höherdimensionalen Raum implizit durchgeführt. Die Funktion $\varphi(x_i)$, welche die Transformation beschreibt, wird daher nicht direkt benötigt. Im Folgenden wird neben der linearen SVM hauptsächlich der RBF-Kernel verwendet:

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right). \tag{3.20}$$

Die Einführung der Begriffe Situation, Episode, Episodenraum, Situationsraum und Kritikalität bilden die Grundlage für die vorlegende Arbeit. Die in diesem Kapitel vorgestellten Verfahren werden in den folgenden Kapiteln verwendet, um Situationsdatensätze zu generieren und zu untersuchen.

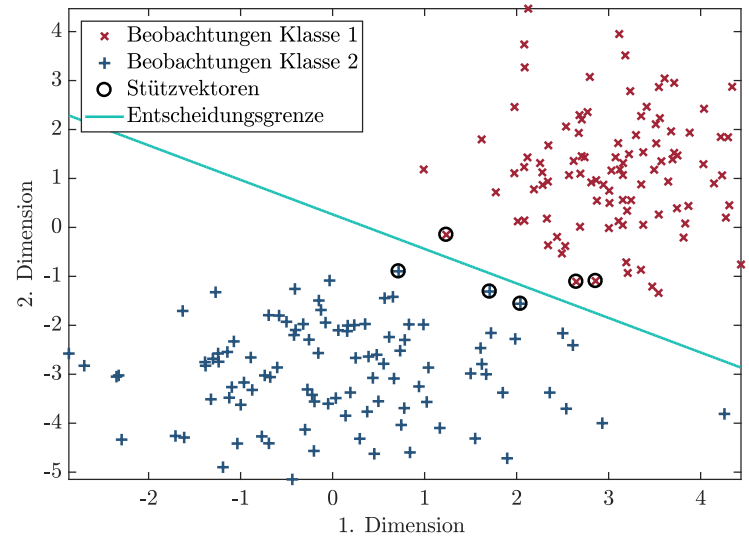

(a) Lineare SVM

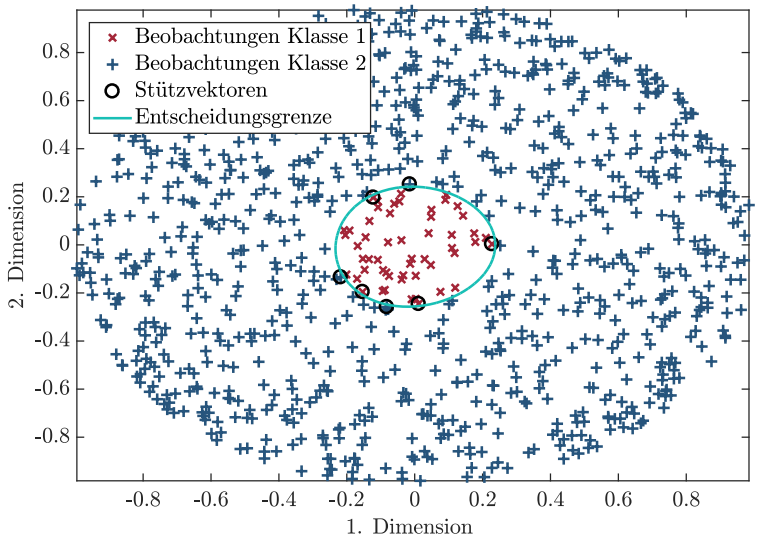

(b) SVM mit RBF-Kernel

Abbildung 3.8: Beispielhafte Darstellung der Entscheidungsgrenze einer gelernten SVM. Die beiden zu trennenden Klassen sind mit roten Kreuzen (x) und blauen Pluszeichen (+) gekennzeichnet. Die schwarzen Kreise (○) markieren die verwendeten Stützvektoren.

Kapitel 4

Datensatzgenerierung

Im folgenden Kapitel werden die erstellten und verwendeten Datensätze vorgestellt. Hierbei liegt der Fokus weniger auf den tatsächlichen Datenpunkten, also den verwendeten Situationen, sondern auf der Beschreibung wie diese erstellt wurden. Dies umfasst die Beschreibung der Verfahren zur Trajektorien- und Episodengenerierung, sowie die Vorstellung des zweistufigen Bewertungsverfahrens.

4.1 Trajektorienberechnung

Die Definition einer Episode macht keine Vorgabe zur konkreten Wahl der Funktion $f(t)$, welche die Fahrzeugpositionen zum Zeitpunkt t bereitstellt. Daher behandelt dieser Abschnitt die Wahl der verwendeten Trajektorienberechnung. Die in Abschnitt 3.6 vorgestellten Tschebyschow-Polynome bilden dabei den Grundbaustein. Sie modellieren die Beschleunigungen $a_{i,x}$ und $a_{i,y}$ der Fahrzeuge, welche anschließend über zweifache Integration in die Fahrzeugposition übergehen. Der Zeithorizont einer Episode beträgt in dieser Arbeit, soweit nicht anders definiert, zehn Sekunden. Im Folgenden werden Episoden $\mathcal{E}_\mathcal{S} = \{\zeta_0, \ldots, \zeta_{N-1}\}$ stets aus den Trajektorien

$$\zeta_i(t) = \begin{pmatrix} f_{i,x}(t) \\ f_{i,y}(t) \end{pmatrix} = \begin{pmatrix} \int_0^t v_{i,x}(\tau)d\tau + p_{i,x,0} \\ \int_0^t v_{i,y}(\tau)d\tau + p_{i,y,0} \end{pmatrix} \tag{4.1}$$

$$= \begin{pmatrix} \int_0^t \left[\int_0^\tau a_{i,x}(\eta)d\eta + v_{i,x,0}\right] d\tau + p_{i,x,0} \\ \int_0^t \left[\int_0^\tau a_{i,y}(\eta)d\eta + v_{i,y,0}\right] d\tau + p_{i,y,0} \end{pmatrix} \tag{4.2}$$

aufgebaut [SKPD16]. Hierbei ist t die in das Intervall $[-1, 1]$ transformierte Zeit gemäß Gleichung 3.17. Um den gewünschten Zeithorizont von zehn Sekunden zu erhalten werden $a = 0$ und $b = 10$ gesetzt. Zusätzlich sind $v_{i,\cdot,0}$ und $p_{i,\cdot,0}$ die Startwerte, welche durch die Situation $\mathcal{S}$ vorgegeben werden. Die Berechnung der

Beschleunigungen beruht hierbei auf Gleichung 3.16 wobei die Implementierung aus [PFTV07] stammt:

$$a_{i,x}(\eta) = \frac{c_0}{2} + \sum_{k=1}^{n-1} c_k T_k(\eta) \text{ und} \tag{4.3}$$

$$a_{i,y}(\eta) = \frac{d_0}{2} + \sum_{k=1}^{n-1} d_k T_k(\eta). \tag{4.4}$$

Die Variablen sind hier c_k und d_k, welche die Episodenparameter darstellen. Zur Erstellung einer neuen Episode genügt es, c_k und d_k zu wählen.

In der vorliegenden Implementierung werden stets Polynome vierten Grades verwendet. Daher werden pro Richtung fünf Parameter benötigt, wodurch die Trajektorie eines Fahrzeugs durch zehn Werte definiert ist. In den Arbeiten von Hermes [HWSK09; HWW+11] wird ein ähnliches Verfahren angewendet. Dort werden die Trajektorien über die Geschwindigkeit und den Gierwinkel dargestellt, diese werden wiederum mit Tschebyschow-Polynomen approximiert.

4.2 Episodengenerierung

Die im Grundlagenkapitel 3 vorgestellten Situationen und Episoden sollen zur späteren Verwendung in Datensätzen gespeichert werden. Hierzu ist es zunächst hilfreich, wenn alle zu einer Situation gehörigen Episoden abgespeichert werden können. Dies wird hauptsächlich für die Überprüfung einzelner Episoden und der Funktionstüchtigkeit der gesamten Verarbeitungskette benötigt. Ist dies gewährleistet, genügt die Speicherung der überprüften Situationen zusammen mit der berechneten Kritikalität. Zur Speicherung einer Episode werden die Koeffizienten der Tschebyschow-Polynome aller beteiligter Fahrzeuge abgelegt, wodurch eine $N \times 2k$-Matrix entsteht, bei der jede Zeile die Trajektorienkoeffizienten eines Fahrzeugs enthält.

$$\mathcal{E}_{\mathcal{S}} = \underbrace{\left(\begin{array}{ccc|ccc} c_{0,0} & \cdots & c_{0,k-1} & d_{0,0} & \cdots & d_{0,k-1} \\ \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ c_{N-1,0} & \cdots & c_{N-1,k-1} & d_{N-1,0} & \cdots & d_{N-1,k-1} \end{array}\right)}_{\substack{x\text{-Beschleunigung} \\ \qquad\qquad\qquad\

4.2.1 Episodenrasterung

Die erste Möglichkeit der Episodengenerierung besteht in der Vorgabe der zu verwendenden Koeffizienten und deren Kombination. Hierbei können für die individuellen Parameter unterschiedliche Vorgaben an Wertebereiche gestellt werden, wodurch eine flexiblere Episodenauswahl getroffen werden kann. Die Ganzheit der möglichen Parameter wird hier mit *Parameter Rate* (PR) bezeichnet, in Anlehnung an die Abtastrate eines Intervalls. Zusätzlich kann für jedes betrachtete Fahrzeug eine eigene PR erstellt werden, deren Zusammenführung im *Parameter Vector* (PV) geschieht und damit alle möglichen Episoden für eine Situation bereithält. Formal lässt sich die PR $\mathcal{R}_i$ des Fahrzeugs i als Menge von Mengen auffassen:

$$\mathcal{R}_i = \{C_i, D_i\}, \quad i = 0, \ldots, N-1 \tag{4.6}$$

$$\text{mit } C_i = \{\tilde{c}_{i,j}\}, D_i = \{\tilde{d}_{i,j}\} \tag{4.7}$$

Hierbei beschreibt C_i die Menge über den Mengen $\tilde{c}_{i,j}$ der einzelnen Beschleunigungsparameter $c_{i,j,l}$ für die x-Richtung. Analog ist die Menge D_i für die y-Beschleunigungsparameter definiert. Der Index $i = 0, \ldots, N-1$ läuft über die Anzahl der Fahrzeuge, welche in der Situation betrachtet werden. Der Index $j = 0, \ldots, k-1$ läuft über die Anzahl der Polynomkoeffizienten zur Darstellung der Beschleunigungsverläufe. Der Index $l = 0, \ldots, p_{i,j} - 1$ läuft über die Anzahl der möglichen Werte des Koeffizienten $c_{i,j,l}$ des Fahrzeugs i, das heißt $p_{i,j} = |\tilde{c}_{i,j}|$ und $q_{i,j} = |\tilde{d}_{i,j}|$. Und $\mathcal{V}_\mathcal{S} = \{\mathcal{R}_i\}$ ist der PV einer Situation $\mathcal{S}$.

Um eine möglichst freie Parameterwahl und damit auch Episodenwahl zu ermöglichen, können alle $p_{i,j}$ und $q_{i,j}$ unabhängig voneinander Werte größer Null annehmen. Die PR $\mathcal{R}_i$ definiert durch diese Darstellung $|\mathcal{R}_i| = \prod_{j=0}^{k-1} p_{i,j} \prod_{j=0}^{k-1} q_{i,j}$ verschiedene Trajektorien für das Fahrzeug i. Durch die Kombination der Trajektorien der betrachteten Fahrzeuge lassen sich durch einen PV $\mathcal{V}$ insgesamt $|\mathcal{V}| = \prod_{i=0}^{N-1} |\mathcal{R}_i|$ viele Episoden speichern.

Diese Darstellung hat mehrere Vorteile:

Reproduzierbarkeit
: Ein abgespeicherter PV generiert stets die gleichen Episoden, solange die Ausgangssituation nicht verändert wird. Hierdurch lassen sich gezielte Untersuchungen, siehe *Parametervorgabe*, einfach reproduzieren und abspeichern, siehe *Speicherplatz*.

Parametervorgabe
: Die Werte der einzelnen Koeffizienten eines Fahrzeugs können unabhängig voneinander vorgegeben und verändert werden. Somit können Koeffizienten

gezielt auf ihren Einfluss auf die Episodenausprägung untersucht werden. Zusätzlich kann leicht Einfluss auf die erwartete Komplexität der Episoden genommen werden, da keine anderen Werte, als die vorgegebenen, benutzt werden.

Speicherplatz

Bei der intuitiven Speicherung jeder Episode werden $N \cdot 2 \cdot k$ Zahlenwerte für eine Episode benötigt. Daher steigt der Speicherbedarf linear mit der Anzahl der betrachteten Episoden. Bei der Speicherung durch einen PV hingegen werden die verwendeten Werte jeweils einmal gespeichert. Der genaue Speicherbedarf für eine bestimmte Anzahl Episoden hängt dabei sehr stark von der Verteilung der Werte über die vorhandenen Parameter ab. Wird im ungünstigen Fall nur ein Parameter mit verschiedenen Werten versehen, wächst der Speicherbedarf auch linear mit der Anzahl der Episoden, wenn auch mit einer geringeren Steigung. Werden bestenfalls alle Parameter gleichermaßen mit möglichen Werten besetzt, wächst der Speicherbedarf logarithmisch.

Für die effiziente Nutzung der PV wird im besten Falle eine bijektive Abbildung zwischen den einzelnen Episoden und einem Zahlenwert benötigt. Damit kann die intuitive Verwendung einer Schleife für jede Parametermenge $p_{i,j}$ und $q_{i,j}$ auf eine einzelne Schleife über die Episodenmenge $|\mathcal{V}|$ reduziert werden. Als Nebeneffekt wird dadurch eine einfache Nebenläufigkeit ermöglicht. Dazu wird die Methode der *gemischten Basen* angewendet („mixed-radix number systems“) [Knu98].

In Abbildung 4.1 sind beispielhaft die Episoden eines PV bestehend aus einem PR abgebildet. Dabei beinhaltet die Menge $\tilde{c}_{0,0}$ mehrere Parameter, alle anderen Parametermengen enthalten nur einen Wert. Dadurch wird zum einen der Einfluss des ersten Parameters sichtbar, es ändert sich ausschließlich die x-Geschwindigkeit des Fahrzeugs zwischen den verschiedenen Trajektorien.

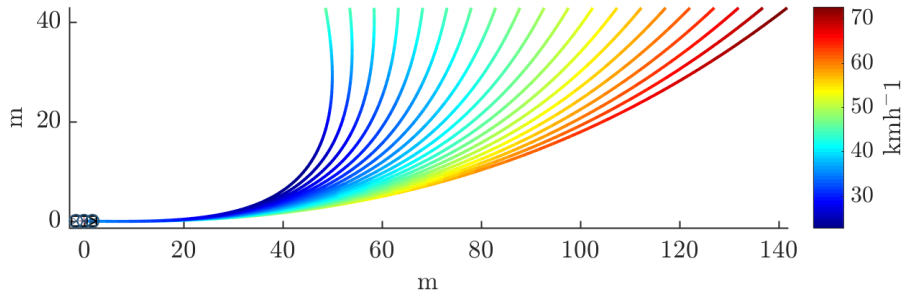

Abbildung 4.1: Darstellung der verschiedenen Episoden eines Fahrzeugs bei Variation eines einzelnen Parameters $c_{0,0}$.

Der große Nachteil dieser Methode ist die Notwendigkeit, alle verwendeten Parameter im Voraus angeben zu müssen. Dadurch können zwar bestimmte Episoden gezielt untersucht werden, allerdings vielfältige Episoden nur aufwendig generiert werden. Daher wird im Folgenden ein Verfahren verwendet, bei dem in einem vorgegebenen Intervall zufällig Parameter gezogen werden.

4.2.2 Monte-Carlo-Methode

In diesem Abschnitt wird die Erstellung der Episoden auf Basis des MC-Verfahrens erläutert. Aus den Erfahrungen aus dem vorangegangen Abschnitt kann gefolgert werden, dass eine vielfältige und umfassende Episodengenerierung möglichst viele verschiedene Parameterwerte benötigt. Somit bietet sich die zufällige Wahl der Koeffizienten und daraus folgend die zufällige Generierung der Episoden an. Bei der Umsetzung stehen mehrere Möglichkeiten zur Auswahl:

- Völlig zufällige Koeffizientenwahl
- Direkte Berücksichtigung einiger Situationsparameter (Status)
- Berücksichtigung aller Situationsparameter (Status, Limits)

Werden alle Koeffizienten komplett unabhängig voneinander zufällig gezogen, ist die Episodengenerierung nur von der Geschwindigkeit des Zufallszahlengenerators abhängig und benötigt keine weiteren Berechnungsschritte. Allerdings werden die wenigsten Episoden überhaupt den Bedingungen der Situation gerecht, d.h. die geforderten Beschleunigungswerte werden nicht verwendet und Überschreitungen der Limitierungen kommen öfters vor.

Bei der Berücksichtigung aller Situationsparameter hingegen liefert der Generator nur zulässige Episoden, wobei der Berechnungsaufwand um ein Vielfaches höher ist. Nach dieser Methode müssten die Episoden lediglich auf Kollisionen überprüft werden.

Da aber einerseits eine schnelle Berechnung der Episoden im Vordergrund steht und eine genauere Untersuchung durch eine Kollisionsüberprüfung zusätzlich durchgeführt werden muss, wird die folgende Methode verwendet. Die Koeffizienten werden zufällig gewählt, bis auf den linearen Anteil. Dieser wird aus den anderen so berechnet, dass die geforderte (Start-)Beschleunigung der Fahrzeuge in der Situation eingehalten wird. Da die (Start-)Position und (Start-)Geschwindigkeit über die Integration der Beschleunigungsfunktion in die Trajektorie eingehen, werden alle geforderten Statuswerte erfüllt. Die vorgegebenen Limitierungen werden anschließend an die

Generierung überprüft und die Episode wird verworfen, falls eine Trajektorie eine Fahrzeugbeschränkung nicht einhält.

4.3 Episodenbewertung

Nachdem eine Episode durch ein Verfahren, z.B. Episodenrasterung oder Monte-Carlo, erstellt wurde, wird sie auf ihre Eigenschaften untersucht. Dazu zählt zum einen die Einhaltung aller Limitierungen, welche durch die Situation vorgegeben werden, z.B. Höchstgeschwindigkeiten, als auch die Anwesenheit von Kollisionen. Bei Letzteren wird zwischen Kollisionen, die das Ego-Fahrzeug betreffen und Kollisionen an denen ausschließlich andere Fahrzeuge beteiligt sind, unterschieden.

Hierbei werden die Episoden in folgende Kategorien eingeteilt:

physikalisch unplausibel
: Bei den physikalisch unplausiblen Episoden werden die durch die Situation vorgegebenen Limitierungen $\mathfrak{L}$ durch mindestens ein Fahrzeug verletzt. Überprüft wird die Einhaltung der vorgegebenen Beschleunigungs- und Geschwindigkeitsgrenzen. Die unplausiblen Episoden werden sofort verworfen und werden nicht für die aufwendigere Kollisionsberechnung herangezogen. Alle Episoden, in denen die Trajektorien der Fahrzeuge alle Beschränkungen einhalten, werden als *(physikalisch) plausibel* bezeichnet und gehen in die Kritikalitätsbewertung ein.

kritisch
: Als kritisch wird eine Episode betrachtet, wenn das Ego-Fahrzeug in eine Kollision mit einem anderen Fahrzeug verwickelt ist. Synonym dazu wird auch von *kollisionsbehafteten* Episoden geschrieben. Episoden, welche unplausibel sind, werden nicht auf Kollisionen überprüft und finden sich nicht in dieser Kategorie wieder.

unkritisch
: Alle Episoden, die physikalisch plausibel und kollisionsfrei sind, werden als *unkritisch* bezeichnet. Hierbei ist zu beachten, dass nur Kollisionen berechnet werden, in die das Ego-Fahrzeug verwickelt ist.

Diese Beschreibung impliziert, dass Folgekollisionen oder komplexe Unfallhergänge nicht in diesem Verfahren abgebildet werden. Folgende Gedankenkonstruktion findet sich daher hier nicht wieder: Das Ego-Fahrzeug fährt hinter zwei nebeneinander vorausfahrenden Fahrzeugen. Diese kollidieren durch einen Fahrfehler und verzögern

bis zum Stillstand. Wird das Ego-Fahrzeug nun ebenso in diese Kollision verwickelt, oder nicht?

Die durch die Kollision bedingte Verzögerung wird in den hier berechneten Episoden nicht direkt berücksichtigt. Allerdings ist es durch die zufällige Episodengenerierung durchaus möglich, dass Trajektorien generiert werden, in welchen den vorausfahrenden Fahrzeugen eine ähnliche Trajektorie zugewiesen wird, wie sie nach einer Kollision auftreten würde.

Des Weiteren ist es bei dem vorgestellten Verfahren möglich, genau die Situation darzustellen, welche durch die Kollision in der obigen Episode entsteht. Diese kann dann mit einer Kritikalität belegt werden und es findet implizit eine Bewertung der Kollision zweier anderer Fahrzeuge statt.

4.3.1 Referenzpunktmethode

Für die Überprüfung, ob Kollisionen vorliegen, müssen die Abstände zwischen den Fahrzeugen bekannt sein. Eine grobe Näherung dafür ist der euklidische Abstand zwischen den Referenzpunkten zweier Fahrzeuge.

$$d_c(\zeta_i(t), \zeta_j(t)) = \|\zeta_i(t) - \zeta_j(t)\|_2 \tag{4.8}$$

$$= \left\| \begin{pmatrix} f_{i,x}(t) \\ f_{i,y}(t) \end{pmatrix} - \begin{pmatrix} f_{j,x}(t) \\ f_{j,y}(t) \end{pmatrix} \right\|_2 \tag{4.9}$$

$$= \sqrt{(f_{i,x}(t) - f_{j,x}(t))^2 + (f_{i,y}(t) - f_{j,y}(t))^2} \tag{4.10}$$

Die Trajektorien $\zeta_i(t)$ und $\zeta_j(t)$ der Fahrzeuge i und j beschreiben die Lage der Referenzpunkte zu jedem Zeitpunkt t. Falls $d(\zeta_i(t), \zeta_j(t)) = 0$ gilt, liegt sicher eine Kollision vor, allerdings ist dieser Fall sehr selten und Kollisionen auch bei $d(\zeta_i(t), \zeta_j(t)) \leq \epsilon$ wahrscheinlich. Daher ist es sinnvoll, das Minimum von (4.10) zu bestimmen und damit für bestimmte Werte eine sichere Aussage zu treffen. Die Idee dahinter ist: Für große minimale Abstände kann eine Kollision sicher ausgeschlossen werden und für kleine minimale Abstände liegt eine Kollision sicher vor. Die Quantifizierung dieser Werte hängt von den Ausmaßen der betrachteten Fahrzeuge ab. Seien die Dimensionen des Fahrzeugs i die Länge l_i und die Breite w_i, für Fahrzeug j analog l_j und w_j, dann ist $\overline{d_c} = \frac{\sqrt{l_i^2+w_i^2}+\sqrt{l_j^2+w_j^2}}{2}$ und $\underline{d_c} = \frac{w_i+w_j}{2}$. Im Bereich $\underline{d_c} \leq \Omega_f \leq \overline{d_c}$ kann durch die Referenzpunktmethode keine Aussage getroffen werden. Dazu bedarf es einer detaillierteren Methode. Die Grenzen $\underline{d_c}$ und $\overline{d_c}$ gelten, falls sich der Referenzpunkt mittig in der Fahrzeugfläche befindet, andernfalls sind beliebige Kombinationen möglich. Ohne Berücksichtigung der Lage

der Referenzpunkte, ist das Supremum des Bereichs Ω_f gleich der Summe der Diagonalen der betrachteten Fahrzeuge und das Infimum gleich Null.

4.3.2 Kreismethode

Für den Bereich $\underline{d_c} \leq \Omega_f \leq \overline{d_c}$ wird folgende Idee umgesetzt [ZS10]: Die Umrisse eines Fahrzeugs werden in der vorliegenden Situationsdefinition als Rechtecke angenommen. Die Berechnung des Abstands zweier beliebiger Rechtecke ist verhältnismäßig aufwendig [GLMH96; LLS+15]. Daher bietet es sich an, jedes Rechteck durch Kreise zu überdecken, welche anschließend paarweise auf ihren Abstand überprüft werden. Hierzu reicht das Wissen um die Position des Mittelpunkts und den Wert des Radius aus, da ein Kreis, im Gegenteil zu einem Rechteck radial symmetrisch ist.

In Abbildung 4.2 wird ein typischer Pkw-Umriss auf ein Rechteck reduziert, dieses wird wiederum durch drei Kreise überdeckt.

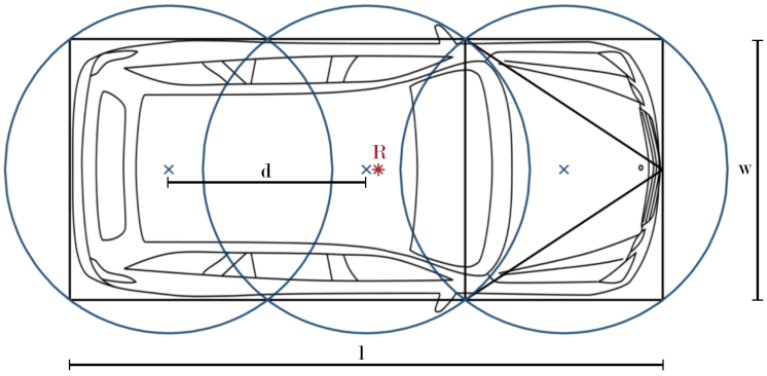

Abbildung 4.2: Die Darstellung eines Fahrzeugs durch ein Rechteck wird wie hier gezeigt durch Kreise approximiert.

Für die Überdeckung kann auch eine andere Anzahl an Kreisen verwendet werden. Je höher diese ist, desto weniger Fläche wird zusätzlich überdeckt. Allerdings steigt mit der Anzahl an verwendeten Kreisen auch die Rechenkomplexität bei der Kollisionsbestimmung. Die Kreise werden mittig über dem Fahrzeug angeordnet und schließen bündig mit den Ecken des Rechtecks ab.

Die Werte d und r lassen sich direkt aus den bekannten Größen Kreisanzahl n, Fahrzeuglänge l und Fahrzeugbreite w durch

$$r = \sqrt{\frac{l^2}{n^2} + \frac{w^2}{4}} \text{ und } d = 2\sqrt{r^2 - \frac{w^2}{4}} \tag{4.11}$$

bestimmen.

Im Gegensatz zur Referenzpunktmethode, welche direkt auf der kompletten Episode angewendet werden kann, müssen bei der Kreismethode die Fahrzeugpositionen für ausgewählte Zeitpunkte konkret berechnet werden. Durch die Information über die Orientierung des Fahrzeugs können die Positionen der Kreismittelpunkte berechnet werden. Die ausgewählten Zeitpunkte müssen eng genug beieinanderliegen, um auch kürzeste Kollisionen abbilden zu können. Da die Trajektorien aus Gleichung 3.7 als Ganzes definiert werden und die Zustände der Fahrzeuge nicht iterativ in jedem Zeitschritt berechnet werden, haben aufkommende Kollisionen keinen Einfluss auf die generierte Trajektorie. Als zeitlicher Abstand zwischen zwei Auswertungen mittels Kreisapproximation werden 10 ms gewählt. Wodurch bei einer 10 s Trajektorie insgesamt 1001 Auswertungen durchgeführt werden. Unter der Annahme einer maximalen Relativgeschwindigkeit zwischen zwei Fahrzeugen von $200\,\mathrm{km\,h^{-1}}$ errechnet sich eine minimale Genauigkeit von 50 cm. Ist eine höhere Auflösung gewünscht, erhöht sich auch die Anzahl der nötigen Berechnungen, wodurch ersichtlich wird, dass es wünschenswert ist, viele Episoden schon im Voraus mit der Referenzpunktmethode bewerten zu können.

4.4 Kritikalitätsberechnung

Zur Berechnung der Kritikalität $\boldsymbol{\Upsilon}$ einer Situation werden die Anzahl der kollisionsbehafteten Episoden und die Anzahl der generierten plausiblen Episoden benötigt, wie in Gleichung 3.8 beschrieben. Die Anzahl der generierten Episoden hat einen großen Einfluss auf die Bewertung der Situation, da bei einer zu geringen Betrachtung des Episodenraums kein verlässlicher Wert berechnet werden kann. Allerdings ist eine übermäßige Auswertung von Episoden hinderlich für die Auswertung großer Mengen an Situationen. Daher wird in diesem Abschnitt auf die Parametrierung der Kritikalitätsberechnung eingegangen.

Zunächst wird eine Standardsituation untersucht, bei der sich das Ego-Fahrzeug mit 25 m Abstand hinter einem vorausfahrenden Fahrzeug befindet. Beide haben eine Geschwindigkeit von $25\,\mathrm{m\,s^{-1}}$. Abbildung 4.3 zeigt diese Situation ohne dazugehörige Episoden.

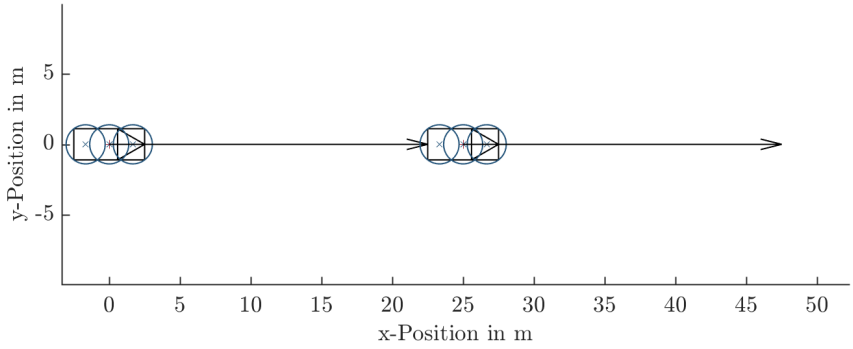

Abbildung 4.3: Folgefahrt zweier Fahrzeuge, das Ego-Fahrzeug befindet sich hinten.

Diese Situation wird in zehn Durchläufen ausgewertet, wobei in jedem Durchlauf die gleiche Situation zehn Mal bewertet wird, jedoch mit unterschiedlicher Anzahl an Episoden. Es wird dabei die Anzahl an *physikalisch plausiblen* Episoden vorgegeben und das MC-Verfahren zieht solange neue Episoden bis die gewünschte Anzahl erreicht ist. Die tatsächlich generierte Anzahl liegt dabei höher, da auch *unplausible* Episoden erzeugt und verworfen werden, welche jedoch nicht zur geforderten Anzahl beitragen. Bei dieser Situation beträgt die Größenordnung der verworfenen Episoden etwa zehn pro verwendete Episode. Die Episodenvorgabe an die einzelnen Durchgänge lautet 5, 10, 50, 100, 500, 1000, 5000, 10 000, 50 000 und 100 000. Das Ergebnis findet sich in Tabelle 4.1.

Tabelle 4.1: Ergebnis der Kritikalitätsbewertung der Situation aus Abbildung 4.3 in zehn Durchläufen.

Episodenanzahl	Mittelwert der Kritikalität	Standardabweichung der Kritikalität
5	0,0535	0,0709
10	0,0550	0,0592
50	0,0592	0,0361
100	0,0528	0,0210
500	0,0576	0,0060
1000	0,0561	0,0088
5000	0,0568	0,0026
10 000	0,0529	0,0021
50 000	0,0543	0,0010
100 000	0,0553	0,0005

Hierbei ist zu erkennen, dass auch bei einer sehr geringen Episodenzahl die Größenordnung der mittleren Kritikalität zu den anderen Werten passt. Allerdings beträgt die Standardabweichung bei fünf Auswertungen über 7 %, was bei einer mittleren Kritikalität von 5,3 % kein unerheblicher Betrag ist. Ab 500 betrachteten plausiblen Episoden fällt die Standardabweichung unter 1 % und lässt damit reproduzierbare Ergebnisse zu.

In einer zweiten Testsituation fahren zwei Fahrzeuge nebeneinander, wobei das untere einen Gierwinkel in Richtung des Ego-Fahrzeugs aufweist. Durch den geringen Abstand der beiden Fahrzeuge mutet die Situation deutlich kritischer an als die erste Testsituation, was auch in der berechneten Kritikalität zum Ausdruck kommt. Die Situation ist in Abbildung 4.4 dargestellt und die Auswertungsergebnisse sind in Tabelle 4.2 zu finden.

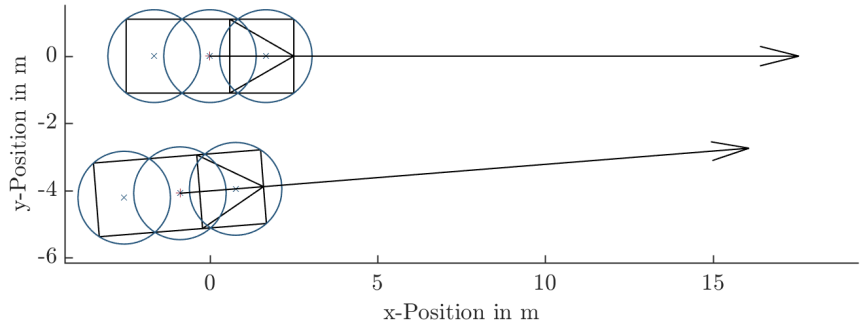

Abbildung 4.4: Geradeausfahrt des Ego-Fahrzeugs, zweites Fahrzeug befindet sich auf dessen rechten Seite und nähert sich.

Hierbei zeigt sich ein ähnlicher Verlauf in Abhängigkeit der Episodenanzahl.

Tabelle 4.2: Ergebnis der Kritikalitätsbewertung der Situation aus Abbildung 4.4 in zehn Durchläufen.

Episodenanzahl	Mittelwert der Kritikalität	Standardabweichung der Kritikalität
5	1,0000	0,0000
10	0,9728	0,0449
50	0,9780	0,0087
100	0,9737	0,0159
500	0,9707	0,0080
1000	0,9711	0,0036
5000	0,9718	0,0026
10 000	0,9727	0,0020
50 000	0,9723	0,0009
100 000	0,9723	0,0002

Ab 500 verwendeten Episoden bleibt die Standardabweichung unter 1 %, bei fast allen Auswertungen liegt die Kritikalität im Bereich um 0,972. In dieser kritischen Situation zeigt sich, dass bei zu geringer Episodenanzahl unter Umständen keine unkritische Episode gefunden werden kann. Deshalb sticht der Durchlauf mit fünf Episoden und einer Kritikalität von 100 % durch eine Standardabweichung von Null heraus.

4.5 Situationsbewertung

Die Auswerteparameter für die später verwendeten Datensätze sind:

- Monte-Carlo Methode
- Keine Speicherung der Episoden
- 3 Durchläufe à 500 physikalisch plausible Episoden je Situation
- Zwischenspeicherung der Ergebnisse alle 1000 Situationen

Die Berechnung erfolgt auf einem Desktop-PC auf Basis eines i7-6850 Prozessors mit sechs Kernen zu je 3,8 GHz. Die Angabe der benötigten Rechenzeit kann nur grob erfolgen, da die benötigte Anzahl an Episoden pro Situation und auch die Menge an Berechnungen pro Episode sehr stark von der Kritikalität der Situation und der Episoden abhängt. Die Dauer je verwendeten Datensatz reicht von fünf bis zehn Stunden, die Menge an Episoden, welche pro Sekunde berechnet werden können, reicht von 20 000 bis 160 000. Durch die Vorgabe, eine bestimmte Anzahl an *plausiblen* Episoden je Situation zu berechnen, hängt die Zahl der tatsächlich generierten Episoden stark von der Beschaffenheit der jeweiligen Situation ab.

In Abbildung 4.5 wird der Gesamtablauf von der Eingabe einer Situation über die Bewertung selbiger bis zur Ausgabe der Kritikalität dargestellt. Hierbei liefert die Episodengenerierung den oberen Teil bis zum Erhalt physikalisch zulässiger Episoden. Der Ablauf der Kollisionsberechnung und Kritikalitätsbewertung wird im unteren Bereich veranschaulicht.

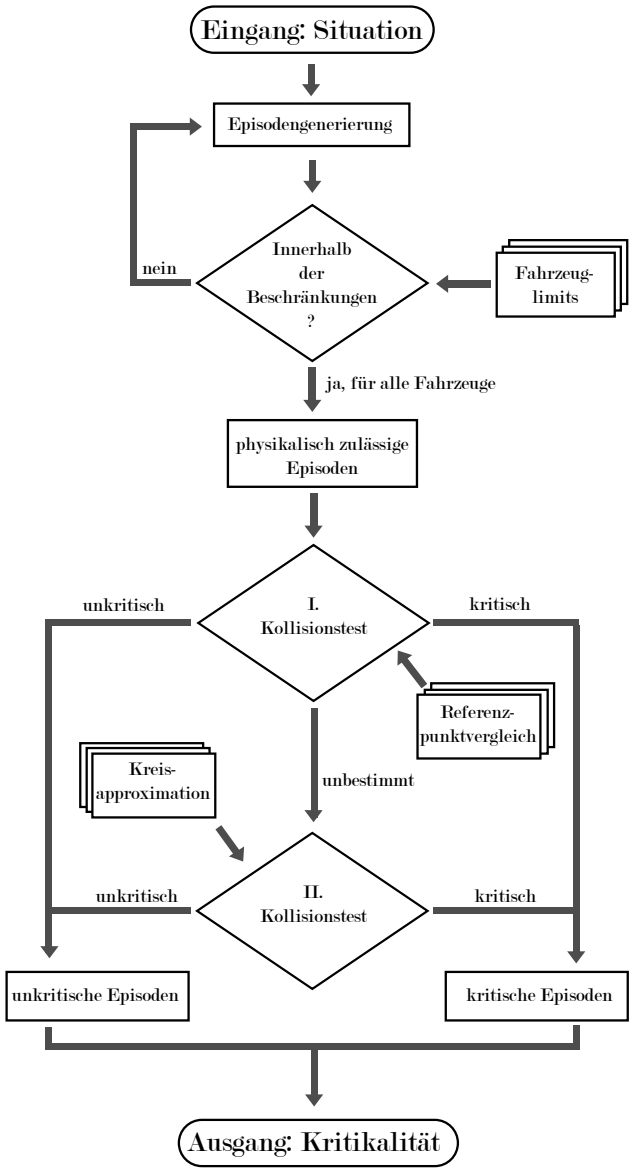

Abbildung 4.5: Schematische Darstellung der Schritte die zur Bestimmung der Kritikalität einer Situation notwendig sind.

4.6 Datensätze

In diesem Abschnitt werden die später verwendeten Datensätze vorgestellt. Zunächst wird eine Eingrenzung der untersuchten Situationsparameter vorgenommen, um die Anzahl der Dimensionen in den Situationsräumen gering zu halten.

Hierfür werden die Beschränkungen $\mathfrak{L}$ aller Fahrzeuge einheitlich auf

$$\mathfrak{l}_i = (-2{,}5,\ 2{,}5,\ -2{,}5,\ 2{,}5,\ 0,\ 55{,}5556,\ -10,\ 10,\ 2{,}5)$$

festgelegt, dies bedeutet eine Beschränkung der Größen:

- Maximalbeschleunigung aller Fahrzeuge in jede Richtung auf $2{,}5\,\mathrm{m\,s^{-2}}$, und maximale kombinierte Beschleunigung auf $2{,}5\,\mathrm{m\,s^{-2}}$
- Geschwindigkeit in x-Richtung aller Fahrzeuge auf $0\,\mathrm{m\,s^{-1}}$ bis $55{,}5556\,\mathrm{m\,s^{-1}}$, ist gleich $0\,\mathrm{km\,h^{-1}}$ bis $200\,\mathrm{km\,h^{-1}}$
- Geschwindigkeit in y-Richtung aller Fahrzeuge auf $-10\,\mathrm{m\,s^{-1}}$ bis $10\,\mathrm{m\,s^{-1}}$, ist gleich $-36\,\mathrm{km\,h^{-1}}$ bis $36\,\mathrm{km\,h^{-1}}$

Es ist zu beachten, dass durch die Wahl eines ortsfesten Koordinatensystems negative Geschwindigkeiten vorkommen. Anschaulich bedeutet eine positive y-Geschwindigkeit eine Linkskurve und eine negative y-Geschwindigkeit eine Rechtskurve. Durch diese Festlegung der Beschränkungen wird die Fokussierung auf Autobahnsituationen deutlich. Dort fahren alle Fahrzeuge tendenziell in die gleiche Richtung, da Rückwärtsfahren untersagt ist und seitliche Bewegungen auf den Spurwechsel oder Auf- und Abfahrten beschränkt sind.

Auch bei der Wahl der Fahrzeugmaße $\mathfrak{G}$ werden die Werte einheitlich auf

$$g_i = (5,\ 2{,}2)$$

gesetzt, wodurch alle Fahrzeuge in den Datensätzen eine

- Länge von $5\,\mathrm{m}$ und eine
- Breite von $2{,}2\,\mathrm{m}$

haben. Die Wahl der Werte richtet sich grob an realen Größen, ist prinzipiell jedoch beliebig. Da die Datensätze in erster Linie zur Überprüfung des Verfahrens an sich gedacht sind und auch die spätere Auswertung des Situationsraums mit verschiedenen

Fahrzeugparametern methodisch genauso ablaufen würde, kann diese Vereinfachung durchgeführt werden. Lediglich bei dem späteren Vergleich mit Realdaten ist es angebracht von vornherein realistische Werte zu verwenden, weshalb dies mit den oben genannten Werten auch so gehandhabt wird.

Des Weiteren werden die Beschleunigungen aller Fahrzeuge der Situation zu Beginn auf null gesetzt, um die Parameteranzahl weiter zu reduzieren. Zur besseren Vergleichbarkeit der Situationen wird das Ego-Fahrzeug in einer Situation stets die Position $(0, 0)$ einnehmen und eine Geschwindigkeit in y-Richtung $v_{0,y} = 0$ haben. Dadurch reduzieren sich die Situationsparameter auf $v_{0,x}$ beim Ego-Fahrzeug und auf $(x_i, y_i, v_{i,x}, v_{i,y})$ für jedes weitere Fahrzeug $i \geq 1$. Die Anzahl der verfügbaren Situationsparameter für N Fahrzeuge ist somit:

$$1 + 4 \times (N - 1). \tag{4.12}$$

Die Anzahl der Fahrzeuge in einem Datensatz ist beliebig. Theoretisch kann jede Situation eine andere Fahrzeuganzahl beinhalten, jedoch wird für die Untersuchung der Methode die einfachste Variante mit zwei Fahrzeugen gewählt. Dadurch wird ein Minimum an Parametern verwendet, da für jedes Fahrzeug zusätzliche Parameter hinzukommen. Hierdurch wird die Dauer der Berechnung der Kritikalität, der Auswertung mittels GPLVM und des Trainings der SVM minimiert und auch der Speicherbedarf gering gehalten. Die untersuchten Verfahren sind allerdings nicht auf eine feste Anzahl an Fahrzeugen oder Parameter beschränkt.

Der Grundaufbau der Datensätze ist in Abbildung 4.6 dargestellt, wo die Standardsituation mit zwei Fahrzeugen gezeigt ist und zusätzlich Pfeile die möglichen Dimensionen anzeigen.

Je nach Auswahl der zu betrachtenden Dimensionen können Datensätze mit bis zu fünf Parametern erstellt werden, was einen (bis zu) 5D-Situationsraum zur Folge hat. Dabei werden zunächst verschiedene Datensätze mit drei ausgewählten Parametern generiert, da diese einfacher visualisiert werden können. Anschließend werden mehrere Datensätze mit fünf Parametern generiert, mit unterschiedlicher Anzahl an Situationen, um eine Auswertung über die nötige Abtastung des Raums anfertigen zu können. Die drei Datensätze mit je drei Parametern setzen sich wie folgt aus den Dimensionen zusammen:

1. Dimensionen a, b und d
2. Dimensionen a, b und c
3. Dimensionen a, b und e

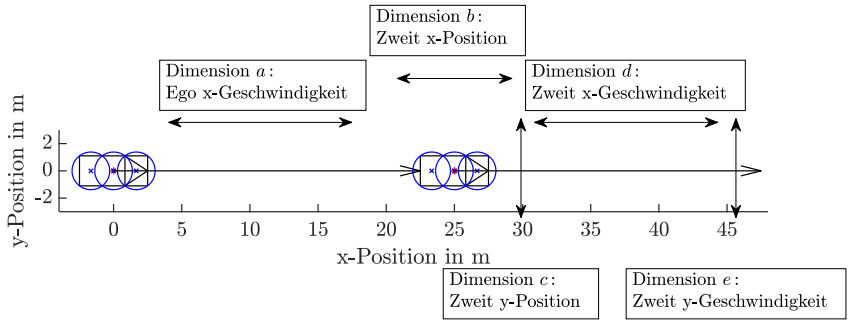

Abbildung 4.6: Darstellung der möglichen Dimensionen a bis e bei zwei Fahrzeugen, aus denen der Situationsraum gebildet werden kann.

Hierbei liegt die Annahme zu Grunde, dass die Ego x-Geschwindigkeit a und die x-Position des anderen Fahrzeugs b die einflussreichsten Parameter sein werden, weshalb diese in jedem Datensatz berücksichtigt werden. Für die anderen sieben Möglichkeiten, drei aus fünf Dimensionen auszuwählen, werden keine eigenen Datensätze generiert, da die drei 3D-Datensätze als Einführungsbeispiele für das Verfahren gedacht sind und die Hauptauswertung auf dem 5D-Datensatz durchgeführt wird, welche alle fünf Dimensionen beinhaltet. Nach der Auswahl der verwendeten Dimensionen stellt sich die Frage nach deren Raster, wobei folgende Wertebereiche pro Dimension festgelegt werden:

Dimension a: $0\,\mathrm{m\,s^{-1}}$ bis $50\,\mathrm{m\,s^{-1}}$

Dimension b: $7\,\mathrm{m}$ bis $50\,\mathrm{m}$

Dimension c: $-10\,\mathrm{m}$ bis $10\,\mathrm{m}$

Dimension d: $0\,\mathrm{m\,s^{-1}}$ bis $50\,\mathrm{m\,s^{-1}}$

Dimension e: $-10\,\mathrm{m\,s^{-1}}$ bis $10\,\mathrm{m\,s^{-1}}$

Diese Bereiche werden jeweils in $1\,\mathrm{m}$ bzw. $1\,\mathrm{m\,s^{-1}}$ Schritten abgetastet. Hierbei entstehen für den ersten Datensatz 114 444 und für die anderen beiden Datensätze 47 124 Situationen. Diese Anzahl an Situationen ist mit einer Rechenzeit von fünf bis zehn Stunden für die Kritikalitätsbewertung eines Datensatzes zeitlich noch berechenbar.

Bei gleichem Raster würden in dem 5D-Datensatz 50 469 804 Situationen generiert werden, was mit einer erwarteten Rechenzeit von ca. sechs Monaten impraktikabel viel ist. Daher werden mehrere 5D-Datensätze mit unterschiedlichen Rastern verwendet, welche insgesamt deutlich weniger Situationen generieren, aber dennoch auf den ganzen Situationsraum verteilt sind [SD18]. Die Güte der Lage dieser Datensätze im gesamten Situationsraum wird durch die Auswertungsleistung der Verfahren in Kapitel 5 bewertet.

Die Abbildungen 4.7 bis 4.9 zeigen jeweils 250 zufällige Situationen der Datensätze, wodurch ein Einblick in die Variation bei der Positionierung und den Geschwindigkeiten gegeben wird. Durch die Länge und Richtung der Pfeile werden die Geschwindigkeiten angezeigt. Das Ego-Fahrzeug befindet sich jeweils in Position $(0, 0)$ und es ändert sich ausschließlich seine x-Geschwindigkeit (Dimension a). Für jede Situation wird ein weiteres zweites Fahrzeug eingezeichnet, wodurch in jeder Abbildung jeweils 250 zweite Fahrzeuge dargestellt sind. Durch die Wahl der Dimensionen b und d in Datensatz 1 (*114k*) verändern sich in Abbildung 4.7 die x-Position und x-Geschwindigkeit des zweiten Fahrzeugs. Wobei die Dimensionen c und e, d.h. die y-Position und y-Geschwindigkeit des zweiten Fahrzeugs, in allen Situationen den gleichen Wert annehmen.

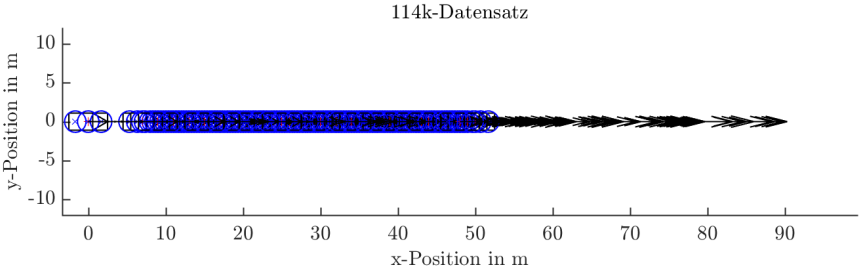

Abbildung 4.7: 250 der 114 444 Situationen zeigen die variierten Parameter in diesem Datensatz: Ego x-Geschwindigkeit, Fremd x-Position und Fremd x-Geschwindigkeit.

In Abbildung 4.8 ist Datensatz 2 (*47k1*) dargestellt, in dem die x- und y-Position des zweiten Fahrzeugs variiert wurde.

In Abbildung 4.9 ist Datensatz 3 (*47k2*) dargestellt, in dem die x–Position und y-Geschwindigkeit des zweiten Fahrzeugs variiert wurde.

Zusätzlich zu den gerasterten Datensätzen werden jeweils, mit den gleichen veränderlichen Parametern, zufällig Situationen generiert und weitere Datensätze erstellt, um die Auswertemethoden später validieren zu können.

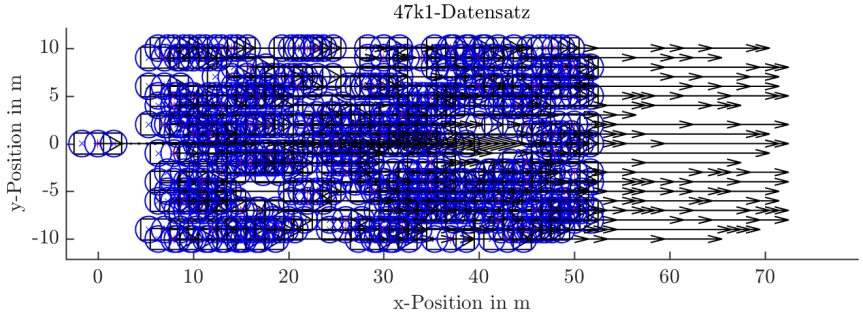

Abbildung 4.8: 250 der 47 124 Situationen zeigen die variierten Parameter in diesem Datensatz: Ego x-Geschwindigkeit, Fremd x-Position und Fremd y-Position.

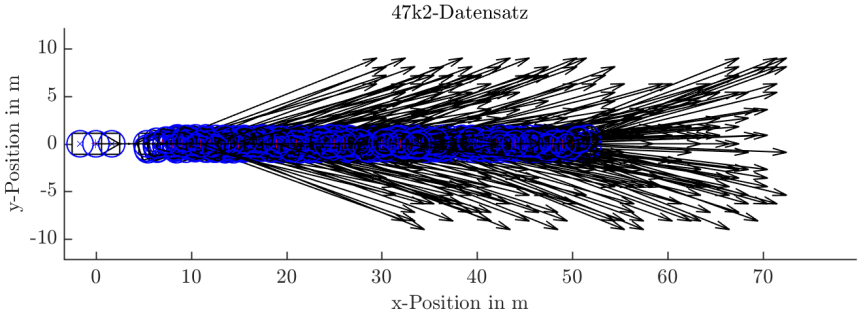

Abbildung 4.9: 250 der 47 124 Situationen zeigen die variierten Parameter in diesem Datensatz: Ego x-Geschwindigkeit, Fremd x-Position und Fremd y-Geschwindigkeit.

Bei der Erstellung der 5D-Datensätze wird das Raster in jeder Dimension so gewählt, dass insgesamt eine vorgegebene Anzahl an Situationen erstellt wird. Die Anzahl an Stützstellen pro Dimension kann hierbei nur ganzzahlig sein, wodurch nicht jede beliebige Gesamtanzahl an Situationen erreicht werden kann. Da sich die Gesamtanzahl multiplikativ aus der Anzahl der Stützstellen der einzelnen Dimensionen zusammensetzt, ergeben sich nur solche mit mindestens fünf Primfaktoren. Um das Raster möglichst komfortabel zu erstellen, wird zunächst eine Wunschgröße $\tilde{\Omega}$ an zu erstellenden Situationen vorgegeben. Diese muss keine Anforderungen an ihre Primfaktoren erfüllen. Die tatsächliche Situationsanzahl Ω im erstellten Datensatz wird folgendermaßen berechnet:

$$\Psi = \sqrt[5]{\frac{R}{\tilde{\Omega}}}, \qquad \text{mit } R = \prod_{i=0}^{4} r_i \tag{4.13}$$

$$\Omega = \prod_{i=0}^{4} \omega_i, \qquad \text{mit } \omega_i = \left\lceil \frac{r_i}{\Psi} \right\rceil \tag{4.14}$$

Hierbei ist R die Bezugsgröße an Situationen bei einem angenommenen Raster von 1 in jeder Dimension und r_i ist die Anzahl an Stützstellen in Dimension i. Diese ergeben sich aus den vorgegebenen Wertebereichen der einzelnen Dimensionen. Die resultierende Stützstellenanzahl pro Dimension ist ω_i, woraus sich die tatsächliche Situationsanzahl Ω berechnet.

Insgesamt werden so sieben 5D-Datensätze mit 12 800, 36 000, 73 008, 84 672, 143 325, 175 616 und 212 415 Situationen erstellt. Im Folgenden werden diese nach der gerundeten Situationsanzahl in Tausend benannt: *13k, 36k, 73k, 85k, 143k, 176k* und *212k*. Durch die verschiedenen Datensätze kann untersucht werden, welche Datensatzgröße notwendig und sinnvoll ist, um den Situationsraum charakterisieren zu können. Es ist zu beachten, dass selbst der Größte hier verwendete Datensatz lediglich 0,4 % der Situationen enthält, die benötigt würden, um das gleiche Raster wie in den 3D-Datensätzen, herzustellen. Zur Validierung werden Datensätze mit 100 000 und 200 000 Situationen zufällig erstellt und bewertet. Durch die zufällige Situationswahl im Vergleich zur gerasterten Auswahl ergibt sich bei einer hohen Anzahl an Situationen eine größere Abdeckung des Situationsraums.

Eine Übersicht der erstellten Datensätze findet sich in Tabelle 4.3. Hierbei gibt die jeweilige Bezeichnung die auf Tausend gerundete Anzahl an Situationen in dem Datensatz an. Diese dient dazu, den Datensatz in späteren Textstellen kurz und eindeutig zu benennen. Eingetragen sind zusätzlich die Anzahl an Dimensionen, die dafür verwendeten Parameter und die Auswertemethode, in der der Datensatz Verwendung findet.

Tabelle 4.3: Übersicht über die erstellten und verwendeten Datensätze.

Bezeichnung	Dimensionen	Parameter	Verwendung in
114k	3	$v_{0,x}, x_1, v_{1,x}$	SVM, GPLVM
47k1	3	$v_{0,x}, x_1, y_1$	SVM
47k2	3	$v_{0,x}, x_1, v_{1,y}$	SVM
13k 36k 73k 85k 143k 176k 212k	5	$v_{0,x}$, x_1, y_1, $v_{1,x}$, $v_{1,y}$	SVM
100k	3	$v_{0,x}, x_1, y_1, v_{1,x}, v_{1,y}$	SVM, GPLVM
200k	5	$v_{0,x}, x_1, y_1, v_{1,x}, v_{1,y}$	SVM

Kapitel 5

Auswertung der Situationsdatensätze

In Kapitel 4 wurden verschiedene Methoden für die Erstellung von Datensätzen erörtert. Die dabei resultierende Variante wurde als Grundlage für alle Datensätze verwendet, welche im vorigen Kapitel erstellt wurden. In diesem Kapitel wird auf die Verwendung der fertigen Datensätze eingegangen, wobei verschiedene Methoden zur Auswertung vorgestellt werden. Grundsätzlich besteht jeder Datensatz aus der Menge von Tupeln $(\mathcal{S}, \boldsymbol{\Upsilon}_{\mathcal{S}})$. Die Intention dabei ist, Erkenntnisse über die für die Änderung der Kritikalität verantwortlichen Eigenschaften der Situationen zu erlangen.

5.1 Motivation

Um eine Aussage über den Einfluss der Situationsparameter auf die Kritikalität zu erhalten, gibt es verschiedene Herangehensweisen. Intuitiv können „alle möglichen“ Situationen ausgewertet und abgespeichert werden. Dann kann jederzeit nachgeschaut werden, ob eine vorliegende Situation kritisch ist oder nicht. Dieses Vorgehen ist jedoch in höchstem Maße impraktikabel, da die Anzahl aller möglicher Situationen als unendlich angenommen werden darf und diese somit nicht mit vertretbarem Aufwand untersucht werden können. Daher soll aus den vorhandenen, endlichen Datensätzen generalisiertes Wissen über Situationen erstellt werden, um daraus anschließend zielführende, *interessante* Situationen generieren zu können. Unter *interessant* werden hierbei Situationen verstanden, welche sich repräsentativ für kritische Bereiche zeichnen, oder welche durch leichte Abänderung eine starke Änderung in der Kritikalität aufweisen. In einem darauffolgenden Schritt können diese Situationen als die benötigten Testfälle verwendet werden.

5.2 *Gaussian Process Latent Variable Model*

Wie in Kapitel 3 vorgestellt, wird das GPLVM im Folgenden verwendet um Strukturen im Situationsraum sichtbar zu machen. Zunächst wurde dafür ein Datensatz mit zwei Fahrzeugen verwendet. Dieser enthält insgesamt 100 000 zufällig erstellte Situationen, welche nach Gleichung 4.12 fünf Parameter verwenden. In Abschnitt 5.2.1 wird dieser genauer beschrieben und gezeigt, dass noch ein weiterer Datensatz benötigt wird. Dafür wird als zusätzlicher Beispieldatensatz der *114k*-3D-Datensatz aus Tabelle 4.3 in Abschnitt 4.6 gewählt. Dieser enthält zwei Fahrzeuge und die Parameter $v_{0,x}, x_1, v_{1,x}$. Die in den Datensätzen beinhalteten Situationen wurden durch Episodengenerierung (Abschnitt 4.2) mit einer Kritikalität (Abschnitt 4.5) bewertet.

Zur Evaluierung wurde die frei verfügbare *Sheffield Machine Learning Software*[11] verwendet. Da es sich bei dem GPLVM um ein überwachtes Lernverfahren handelt, welches als Ziel hat, vorgegebene diskrete Klassen bestmöglich voneinander zu trennen und in eine niedrig-dimensionale Darstellung zu überführen, muss der eingesetzte Datensatz zunächst in ein geeignetes Format gebracht werden.

5.2.1 GPLVM Auswertung des 5D Datensatzes

Zunächst wird für die Evaluierung des GPLVM der fünf dimensionale Datensatz herangezogen. Um die Ergebnisse später interpretieren zu können, wird zunächst eine geeignete Darstellungsmethode des Datensatzes eingeführt. In Abbildung 5.1 ist die Plotmatrix dargestellt, wobei kritische Situationen rot und unkritische Situationen grün eingefärbt sind. Situationen mit einer mittleren Kritikalität werden gelb dargestellt, diese sind mit einem Anteil von 3,3 % praktisch nicht erkennbar. In einer Plotmatrix wird, wie in einer Matrix, in Zeile i und Spalte j die Abbildung des i-ten über den j-ten Parameter des Datensatzes eingetragen. Aus der paarweisen Auftragung der Parameter übereinander lassen sich solche Strukturen visualisieren, die in zwei Dimensionen darstellbar sind. Der Diagonaleintrag (i, i) der Plotmatrix zeigt die Häufigkeitsverteilung des i-ten Parameters. In dem hier dargestellten 5D-Datensatz lassen sich einzelne Häufungen von kritischen Situationen erkennen, weshalb der Datensatz als Test für das GPLVM nützlich erscheint.

Die Zustände der Fahrzeuge werden zufällig, aus den in Tabelle 5.1 vorgestellten Parameterintervallen, gezogen. Die Positionen sind hierbei relativ zum Ego-Fahrzeug zu verstehen, da dieses den Ursprung des Koordinatensystems bildet. Daher gilt

[11] Neil Lawrence, Sheffield Machine Learning Software, Version vom 12.05.2016, Commit 9f0e74f, GitHub Repository, `https://github.com/SheffieldML/GPmat`.

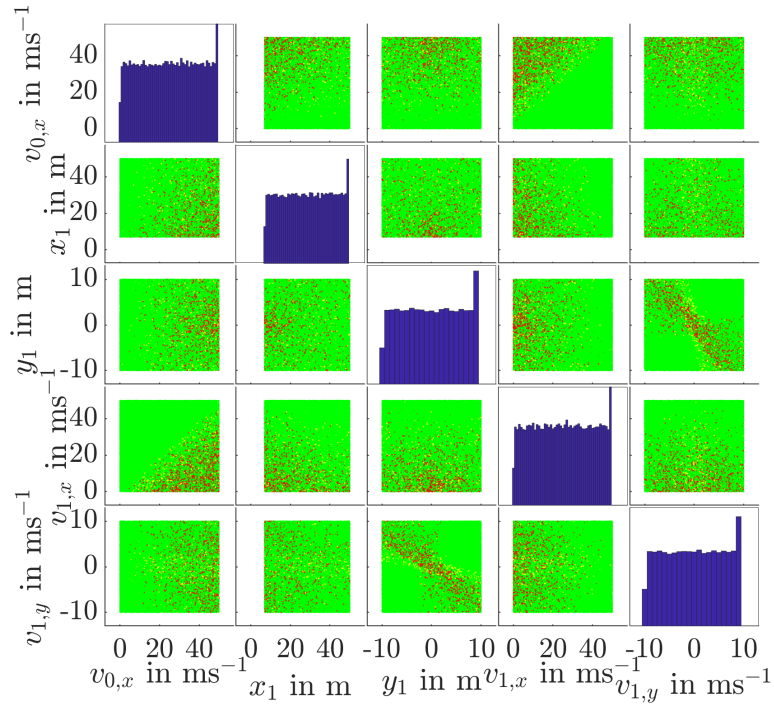

Abbildung 5.1: Plotmatrix des 100k-5D-Datensatzes mit zwei Fahrzeugen. Die Diagonale zeigt die Häufigkeitsverteilung der einzelnen Parameter in blau. Die anderen Einträge zeigen die paarweise Auftragung der fünf Parameter $v_{0,x}, x_1, y_1, v_{1,x}, v_{1,y}$ des Datensatzes. Kritische Situationen sind hierbei rot, unkritische grün und mittel-kritische gelb eingezeichnet.

Tabelle 5.1: Situationsparameterintervalle bei zwei Fahrzeugen

	Min	Max	Einheit
x-Positionen	7	50	m
y-Positionen	-10	10	m
x-Geschwindigkeiten	0	50	$\mathrm{m\,s^{-1}}$
y-Geschwindigkeiten	-10	10	$\mathrm{m\,s^{-1}}$

für den Zustand des Ego-Fahrzeugs z_0, dass $x_0 = y_0 = v_{0,y} = \varphi_0 = 0$ ist und nur die Geschwindigkeit $v_{0,x}$ wird im entsprechenden Intervall zufällig gezogen. Die Parameter des Zustand z_1 des anderen Fahrzeugs werden alle zufällig gezogen.

Die Einteilung der Situationen in Kritikalitätsklassen erfolgt nach Tabelle 5.2.

Tabelle 5.2: Einteilung der Kritikalitätsklassen der Situationen bei zwei Fahrzeugen

	unkritisch	potenziell kritisch	kritisch
Kritikalitätsbereich	0 % bis 20 %	21 % bis 79 %	80 % bis 100 %

Durch die Einteilung in drei Klassen sollte die Unterscheidung in *unkritische*, *potenziell kritische*, und *kritische* Situationen erreicht werden. Die konkrete Wahl der Prozentbereiche erfolgt ohne vorherige Auswertung und dient als eine mögliche Aufteilung. Für das Verfahren sind auch beliebige andere Bereiche verwendbar.

Anschließend werden auf dem vorbereiteten Datensatz mehrere Varianten der GPLVM berechnet. Die Ergebnisse zweier GPLVMs werden in Abbildung 5.2 dargestellt. Von den berechneten 100 000 Situationen sind davon 5000 zufällig gewählte eingezeichnet. Die Einfärbung gemäß den Kritikalitätsklassen erfolgt zur besseren Visualisierung. Dabei wird deutlich, dass das Verfahren in diesem Datensatz keine Struktur finden konnte, um in einer 2D-Darstellung unterschiedliche Cluster auszubilden. Im linken Teil der Abbildung werden alle Situationen ohne sichtbare Ordnung in einem Viereck angeordnet. Im rechten Teil der Abbildung werden die Situationen durch eine andere Parameterwahl bei der GPLVM auf einer ringförmigen Struktur angeordnet. Allerdings ist auch dabei keine Ordnung gemäß der eingefärbten Kritikalität zu erkennen.

Die hohe Anzahl der Dimensionen kann eine Erklärung für das Scheitern der GPLVM

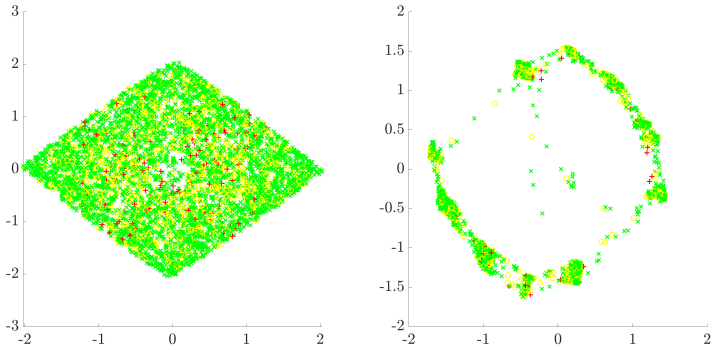

Abbildung 5.2: Ergebnisse der GPLVMs auf dem 5D Datensatz mit zwei Fahrzeugen. Die Situationsmarkierungen sind nach ihrer Kritikalität eingefärbt. Links: Es ist keine Clusterbildung zu erkennen. Rechts: Der Datensatz wird verformt. Strukturen, welche auf eine Einteilung gemäß der Kritikalität schließen lassen, treten jedoch nicht auf.

sein, weshalb das Verfahren im nächsten Abschnitt auf einem Datensatz mit drei Dimensionen getestet wird. Allerdings hat sich das Verfahren in der Literatur gerade bei hochdimensionalen Datensätzen als sehr erfolgreich erwiesen. Daher kann auch der Datensatz selbst ein Grund für das Scheitern sein, indem keine niedrigdimensionale Struktur in den Daten vorhanden ist.

5.2.2 GPLVM Auswertung des 3D Datensatzes

Nachdem für den fünf dimensionalen Datensatz kein GPLVM verwertbare Ergebnisse liefert, wird das Verfahren noch auf einen weniger komplexen Datensatz angewendet. Dafür wird der *114k*-3D-Datensatz herangezogen, welcher bereits in Abbildung 4.7 vorgestellt wurde. Dort als Übereinanderzeichnung mehrerer Situationen in einer Fahrzeugdarstellung. In Abbildung 5.3 ist derselbe Datensatz als Punkte im Situationsraum mit eingefärbter Kritikalität dargestellt.

Für das Training der GPLVMs wird auch hier eine Einteilung der Trainingsdaten nach Tabelle 5.2 vorgenommen.

In Abbildung 5.4 sind die auf dem 114k-Datensatz generierten Ergebnisse zweier GPLVMs mit unterschiedlichen Hyperparametern visualisiert.

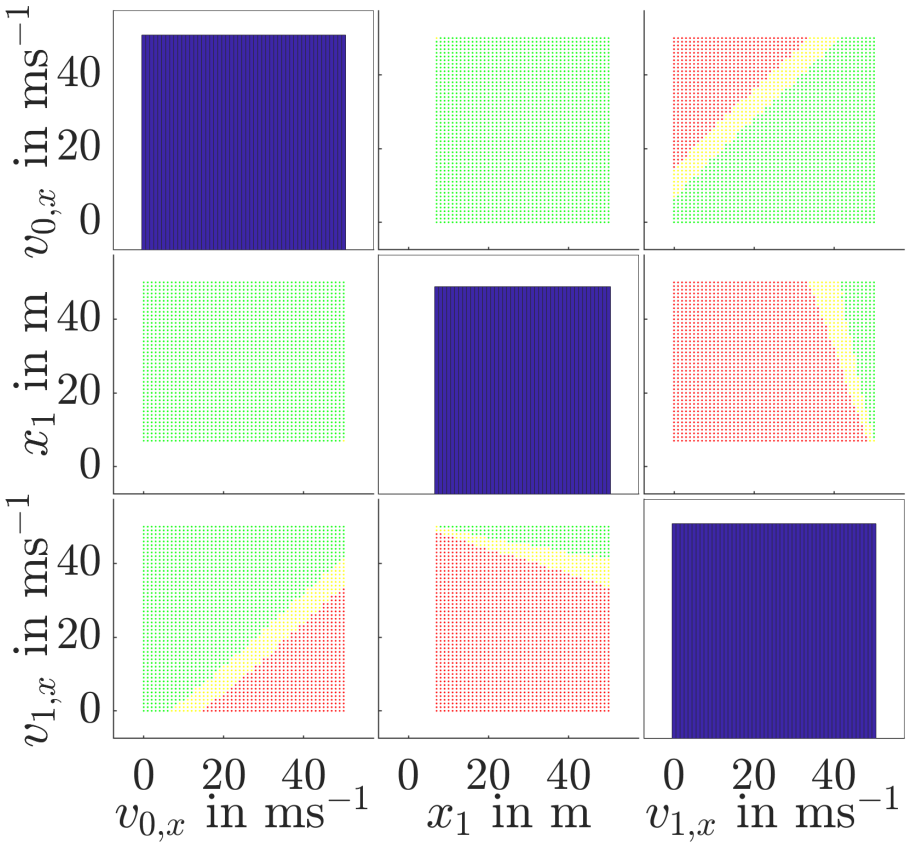

Abbildung 5.3: Plotmatrix des 114k-3D-Datensatzes mit zwei Fahrzeugen. Die Diagonale zeigt die Häufigkeitsverteilung der einzelnen Parameter in blau. Die anderen Einträge zeigen die paarweise Auftragung der drei Parameter $v_{0,x}, x_1, v_{1,x}$ des Datensatzes. Kritische Situationen sind hierbei rot, unkritische grün und mittel-kritische gelb eingezeichnet. Die Charakteristik der kritischen Bereiche wird durch SVMs untersucht.

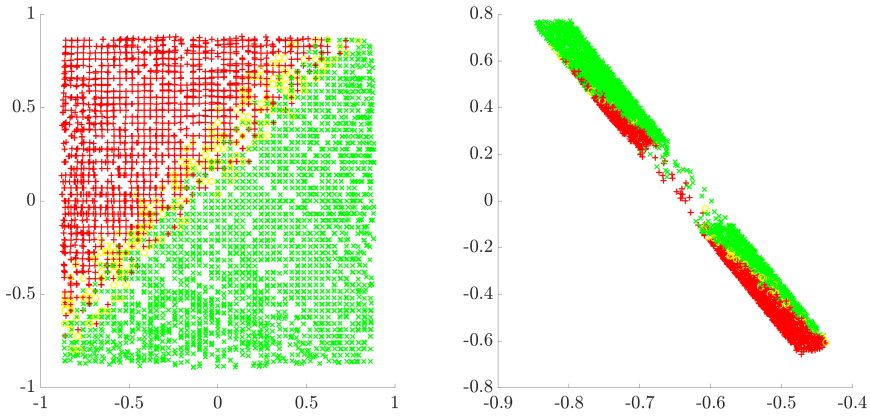

Abbildung 5.4: Ergebnisse der GPLVMs auf dem 114k-Datensatz. Links: beinahe unveränderte Projektion in 2D. Rechts: Ausbildung zweier Cluster, jedoch ohne Zusammenhang zur Kritikalität.

Hierbei sind 5000 der 114 444 Situationen im berechneten latenten Raum eingezeichnet, wobei rote Pluszeichen die kritischen, gelbe Kreise die mittleren und grüne x-Symbole die unkritischen Situationen markieren. Im Ergebnis auf der linken Seite, zeigt sich ein ähnliches Bild wie in Abbildung 5.3 in der ersten Zeile und dritten Spalte. Dieses Ergebnis hat den Datensatz daher größtenteils auf diese beiden Dimensionen reduziert, ohne abgrenzbare Cluster zu erstellen. In der rechten Hälfte der Abbildung, sind die verwendeten Dimensionen nicht ersichtlich. Durch die beiden latenten Variablen werden zwei Cluster ausgebildet, jedoch sind diese nicht deutlich nach der Kritikalität der Situationen getrennt.

5.2.3 GPLVM Diskussion

Insgesamt lässt sich nach Auswertung mehrerer GPLVMs auf mehreren Datensätzen sagen, dass dieses Verfahren leider nicht für die hier vorliegende Problemstellung eignet. Die Anordnung der Datenpunkte beruht größtenteils auf der Anordnung im Datensatz und wird nur durch das nachträgliche Einfärben der Punkte ersichtlich. Es werden keine Cluster ausgebildet, welche die unterschiedlichen Klassen deutlich voneinander abgrenzen. Daraus lässt sich schließen, dass die vorliegenden Daten keine Struktur beinhalten bzw. keine gefunden werden kann, welche sich für eine Clusterbildung mittels GPLVM eignet. Ein erfolgreiches GPLVM wäre der erste Schritt für die Charakterisierung kritischer Situationen. Anschließend müsste eine

Umkehrfunktion im latenten Raum berechnet werden. Diese würde es ermöglichen, aus jedem gefundenen Situationscluster einen Repräsentanten im Situationsraum zu finden. Da auf diesem Weg keine zielführenden Ergebnisse zu erwarten sind, werden weitere Versuche mit GPLVM hier verworfen.

Allerdings ist durch die Untersuchung und Erstellung der benötigten Datensätze ein besseres Verständnis für den Aufbau des Situationsraums entstanden. Da sich in Abbildung 5.3 eine gewisse Ordnung der verschiedenen Kritikalitätsklassen abzeichnet, wird im nächsten Abschnitt ein Klassifizierungsverfahren auf die Datensätze angewandt.

5.3 Charakterisierung mittels *Support Vector Machine*

Als weitere Methode zur Untersuchung des Situationsraums wird eine Charakterisierung mittels SVM durchgeführt. Hierbei werden verschiedene Datensätze und unterschiedlich parametrierte SVMs verwendet, um die grundsätzliche Durchführbarkeit zu demonstrieren und zusätzlich direkt eine möglichst gute Trennbarkeit zu erreichen. In Abbildung 5.5 ist der Grund für die Wahl der SVM als Klassifizierungsmethode ersichtlich. Bei den 3D-Datensätzen ist ein Bereich mittlerer Kritikalität (in Gelb) zu sehen, der den kritischen (in Rot) und unkritischen (in Grün) Bereich im Situationsraum voneinander trennt.

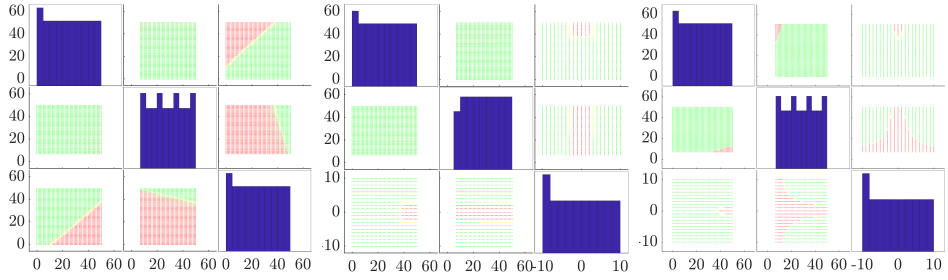

Abbildung 5.5: Ansicht der gerasterten 3D-Datensätze als Plotmatrizen. Die Parameter sind die Ego-x-Geschwindigkeit, die x-Position des anderen Fahrzeugs und (links) die x-Geschwindigkeit, (mittig) die y-Position und (rechts) die y-Geschwindigkeit des anderen Fahrzeugs. Je nach Parameterauswahl ist eine andere Ausprägung des kritischen Bereichs (in Rot) zu erkennen.

Auch in der 3D-Ansicht, Abbildungen 5.6 bis 5.8, ist in den 3D-Datensätzen ein abgegrenzter kritischer Bereich zu erkennen, daher wird zunächst die Funktionsfähigkeit der SVM anhand der in Abschnitt 4.6 vorgestellten 3D-Datensätze ausgewertet.

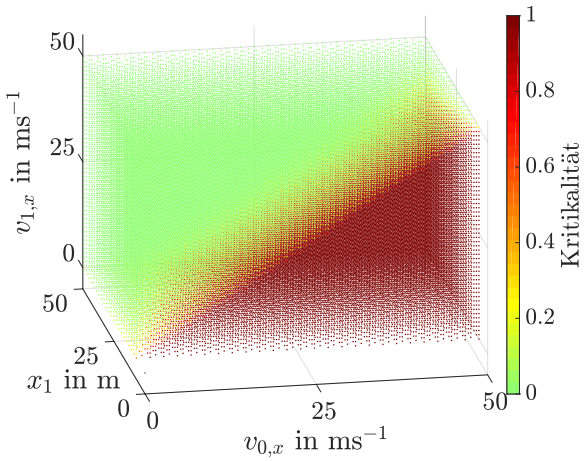

Abbildung 5.6: 3D-Ansicht des *114k*-Datensatzes. Auf der z-Achse wird die x-Geschwindigkeit des anderen Fahrzeugs angegeben. Je höher diese ist und je größer der Abstand zum Ego-Fahrzeug ist, desto geringer ist die Kritikalität der Situation. Übernommen und angepasst mit Erlaubnis aus [SD18] © 2018 IEEE

Die Umsetzung der SVM erfolgt in MATLAB[12] und verwendet dafür die Befehle `fitcsvm` für das Training und `predict` für die Prädiktion. Die Schaubilder sind so gedreht, dass eine möglichst gute Sicht auf die Einteilung des Situationsraums erreicht wird. Die 3D-Datensätze werden jeweils mit drei unterschiedlich parametrierten SVM ausgewertet, es wird jeweils eine andere Kernelfunktion verwendet. Anschließend wird jeder SVM ein zweiter, zufällig gezogener Datensatz zur Bewertung vorgelegt. Daraus lassen sich die Kenngrößen ableiten, welche für die Einschätzung der Güte benötigt werden. Die möglichen Zuordnungen einer Situation durch die SVM befinden sich in Tabelle 5.3. Entgegen der Wortbedeutung ist die *positive*-Klasse hier die Menge der kritischen Situationen. Die hier verwendeten Bewertungsgrößen sind die *richtig-positiv Rate* (auch Sensitivität) ($TPR = \frac{TP}{TP+FN}$), die *falsch-positiv Rate* ($FPR = \frac{FP}{FP+TN}$) und die *Relevanz* ($\frac{TP}{TP+FP}$).

[12] MATLAB® and Statistics Toolbox™ Release 2014b, The MathWorks, Inc., Natick, Massachusetts, United States.

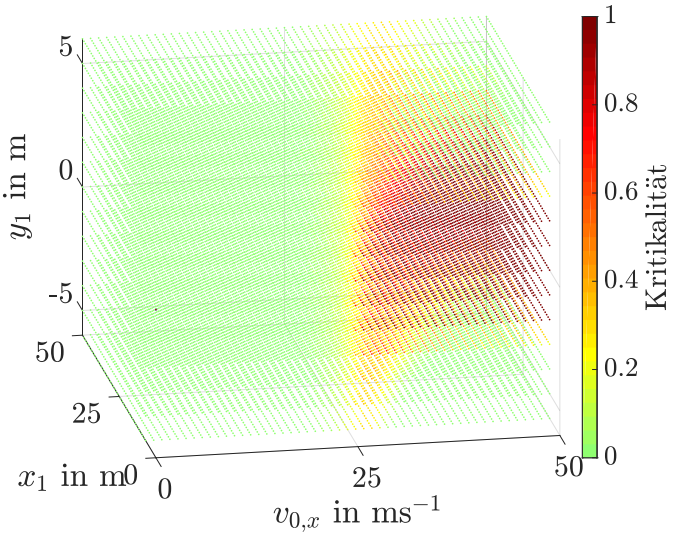

Abbildung 5.7: 3D-Ansicht des *47k2*-Datensatzes. Auf der z-Achse wird die y-Position des anderen Fahrzeugs angegeben. Der kritische Bereich erstreckt sich hier hauptsächlich auf den Bereich vor dem Ego-Fahrzeug bei hohen Geschwindigkeiten.

5.3.1 Auswertung der 3D-Datensätze

Zunächst wird bei der Verwendung der SVM auf die 3D-Datensätze zurückgegriffen, da diese leicht zu visualisieren sind. Dadurch können alle Details in einer 3D-Abbildung dargestellt werden, die Kritikalität der einzelnen Situationen und die Lage der gelernten Stützvektoren.

Abbildungen 5.9 bis 5.14 zeigen die Ergebnisse der gelernten SVMs auf dem *114k*-Datensatz. Abbildungen 5.15 bis 5.20 zeigen die Ergebnisse der gelernten SVMs auf

Tabelle 5.3: Einteilung der Situationen durch eine gelernte SVM

TP	*true-positive* kritische Situation, die als kritisch eingestuft wird
TN	*true-negative* unkritische Situation, die als unkritisch eingestuft wird
FP	*false-positive* unkritische Situation, die als kritisch klassifiziert wird
FN	*false-negative* kritische Situation, die als unkritisch klassifiziert wird

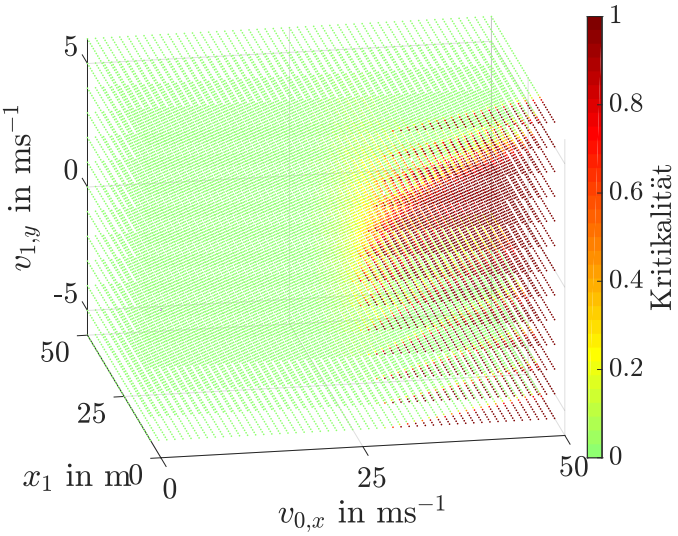

Abbildung 5.8: 3D-Ansicht des *47k2*-Datensatzes. Auf der z-Achse wird die y-Geschwindigkeit des anderen Fahrzeugs angegeben. Der kritische Bereich befindet sich bei hohen Geschwindigkeiten des Ego-Fahrzeugs und geringem Abstand des zweiten Fahrzeugs.

dem *47k1*-Datensatz. Abbildungen 5.21 bis 5.26 zeigen die Ergebnisse der gelernten SVMs auf dem *47k2*-Datensatz.

In Abbildung 5.9 wird der Datensatz *114k* mit einer linearen SVM bewertet. Dabei werden von den 114 444 Situationen 1010 als Stützvektoren ausgewählt, das entspricht einem Anteil von 0,88 %. Bei der anschließenden Validierung in Abbildung 5.10 werden 99,3 % der kritischen Situationen richtig erkannt, und 0,16 % der unkritischen Situationen werden fälschlicherweise als kritisch eingestuft. Dies entspricht einer Relevanz der SVM von 99,7 %.

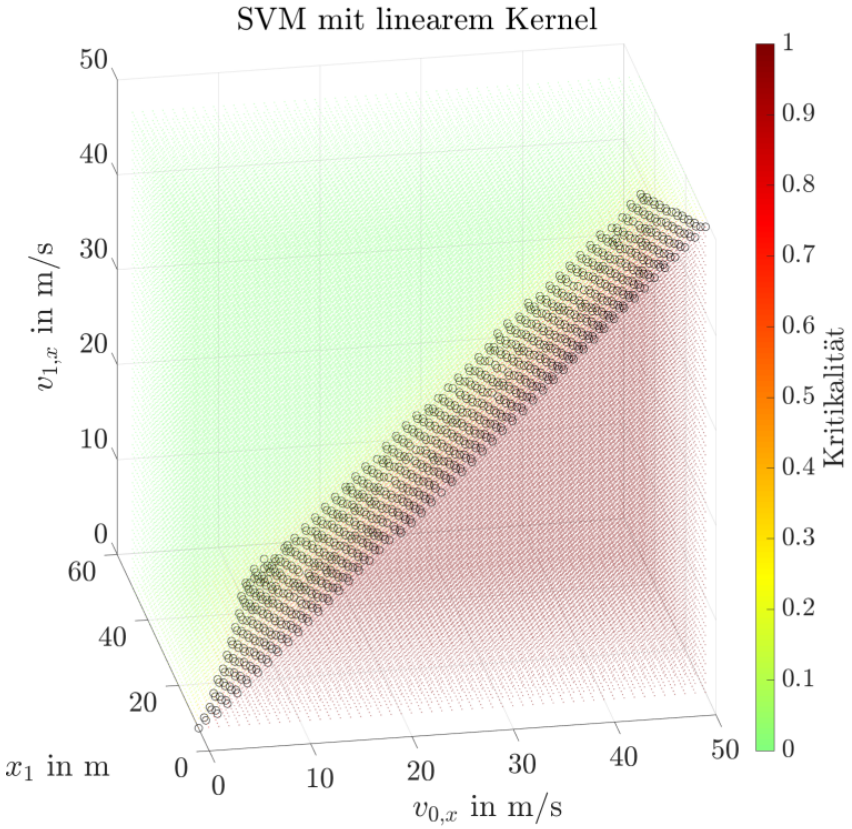

Abbildung 5.9: Die gelernten Stützvektoren sind als schwarze Kreise in den Situationsraum eingezeichnet. Die einzelnen Situationen sind nach ihrer Kritikalität eingefärbt.

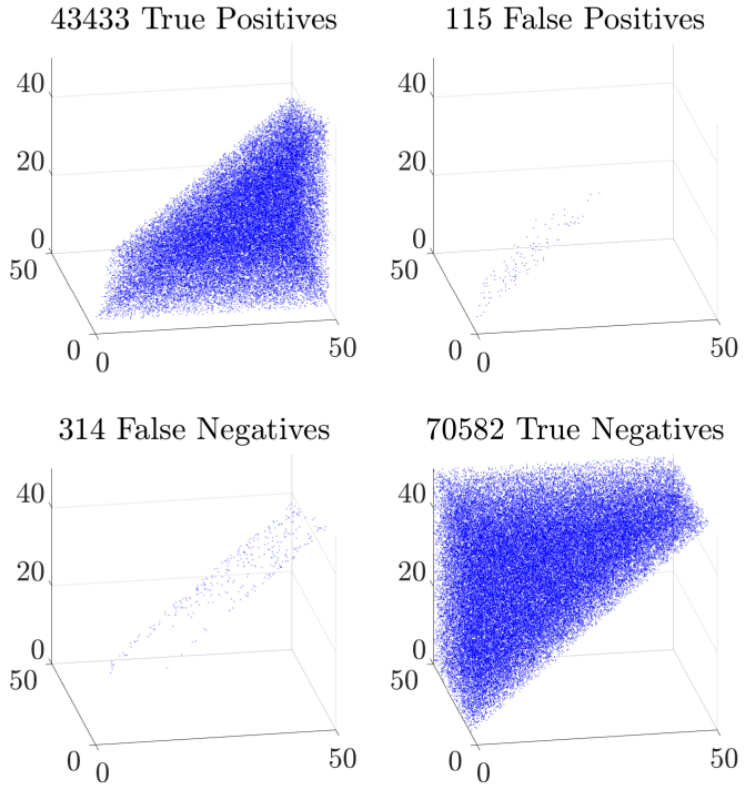

Abbildung 5.10: Die einzelnen Darstellungen zeigen jeweils die Einstufung durch die gelernte SVM auf einem Testdatensatz. Richtig-positiv Rate: 0.99282, falsch-positiv Rate: 0.0016267, Relevanz: 0.99736.

In Abbildung 5.11 wird der *114k* Datensatz mit einer RBF-Kernel SVM bewertet. Dabei werden die Daten in ihrem originalen Wertebereich belassen. Von der SVM werden von den 114 444 Situationen 1644 als Stützvektoren ausgewählt. Das entspricht einem Anteil von 1,4 %. Bei der anschließenden Validierung in Abbildung 5.12 werden 96,3 % der kritischen Situationen richtig erkannt und 6 % der unkritischen Situationen werden fälschlicherweise als kritisch eingestuft. Dies entspricht einer Relevanz der SVM von 90,8 %.

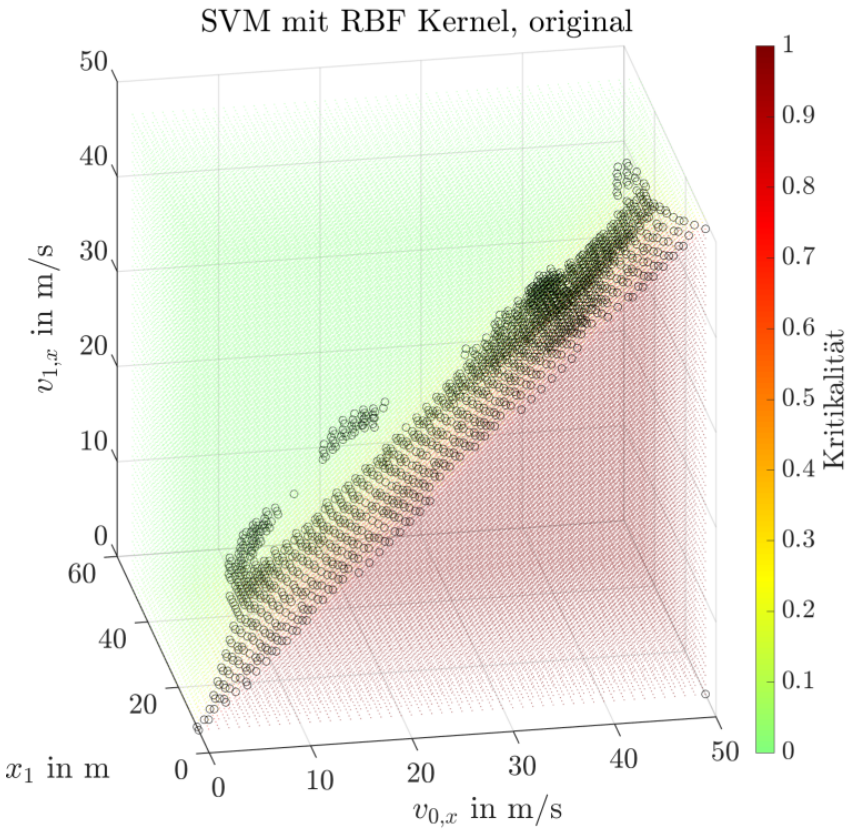

Abbildung 5.11: Die gelernten Stützvektoren sind als schwarze Kreise in den Situationsraum eingezeichnet. Die einzelnen Situationen sind nach ihrer Kritikalität eingefärbt.

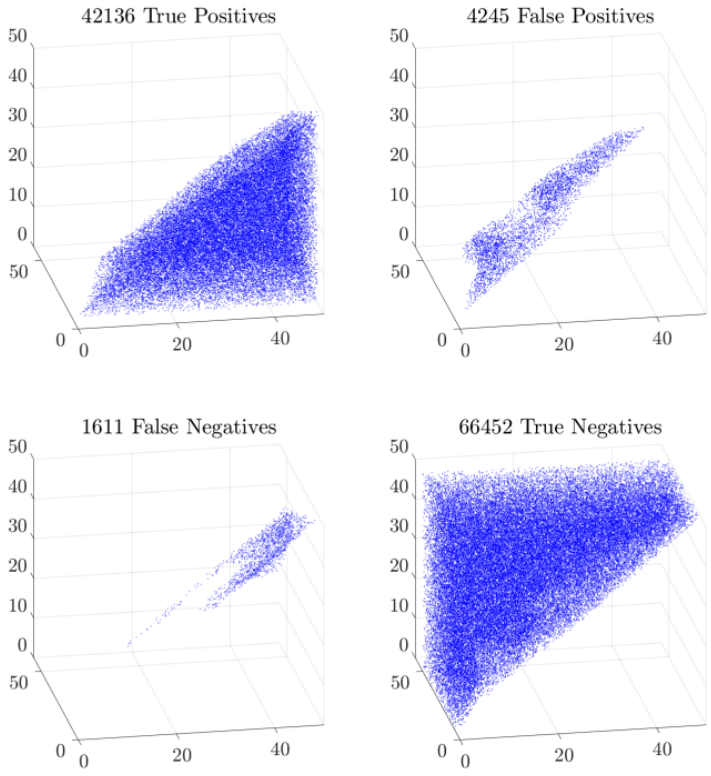

Abbildung 5.12: Die einzelnen Darstellungen zeigen jeweils die Einstufung durch die gelernte SVM auf einem Testdatensatz. Richtig-positiv Rate: 0.96317, falsch-positiv Rate: 0.060045, Relevanz: 0.90848.

In Abbildung 5.13 wird der Datensatz *114k* ebenso mit einer RBF-Kernel SVM bewertet. Die Daten werden hier jedoch in einen normierten Wertebereich überführt. Dadurch werden von den 114 444 Situationen 1070 als Stützvektoren ausgewählt, das entspricht einem Anteil von 0,94 %. Bei der anschließenden Validierung in Abbildung 5.14 werden 83,7 % der kritischen Situationen richtig erkannt, und 16,3 % der unkritischen Situationen werden fälschlicherweise als kritisch eingestuft. Dies entspricht einer Relevanz der SVM von 76,1 %.

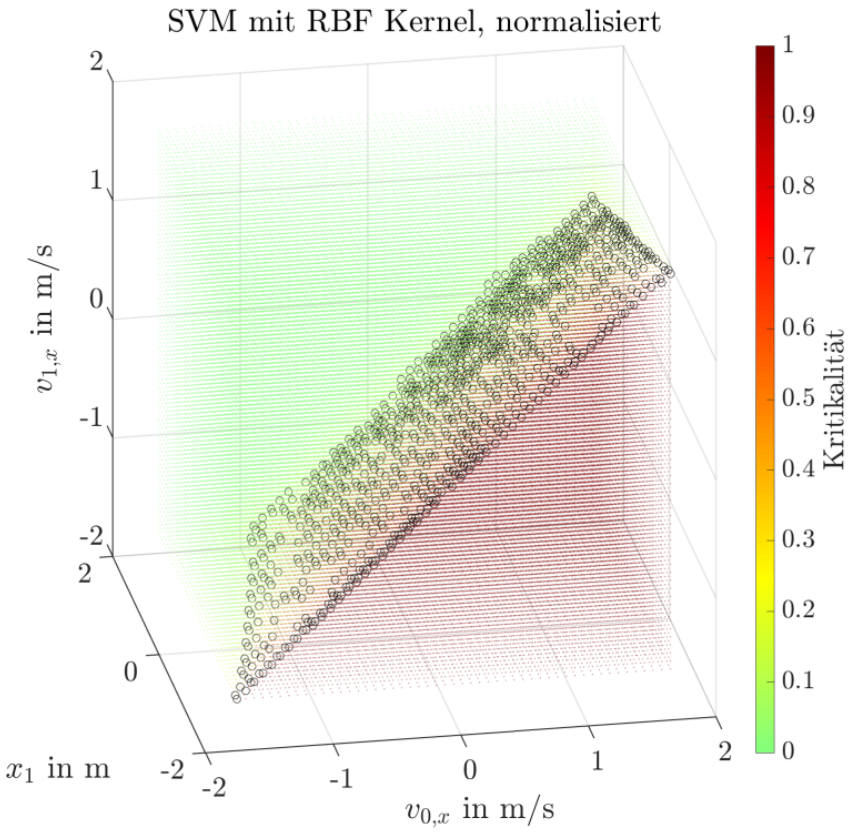

Abbildung 5.13: Die gelernten Stützvektoren sind als schwarze Kreise in den Situationsraum eingezeichnet. Die einzelnen Situationen sind nach ihrer Kritikalität eingefärbt.

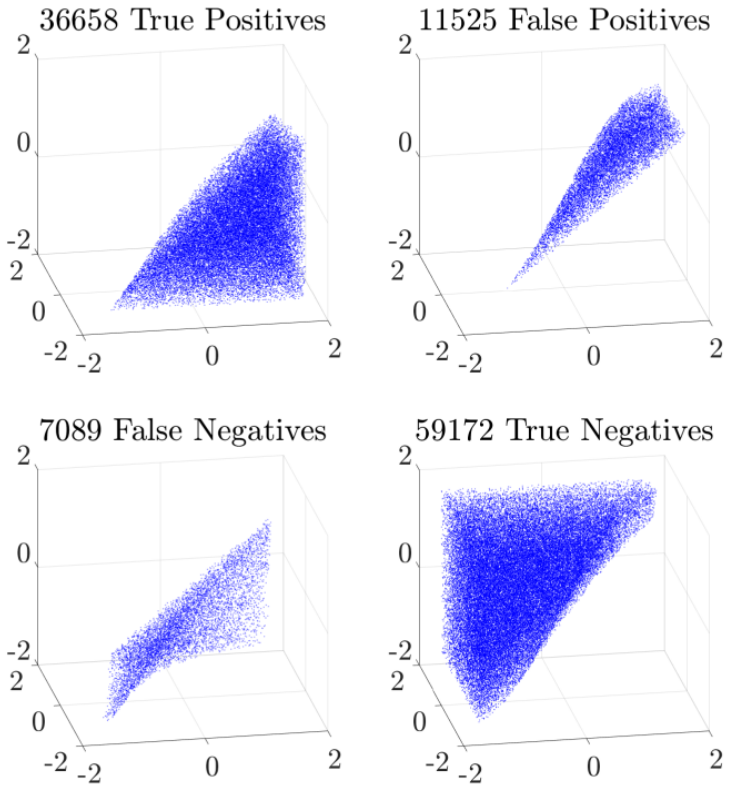

Abbildung 5.14: Die einzelnen Darstellungen zeigen jeweils die Einstufung durch die gelernte SVM auf einem Testdatensatz. Richtig-positiv Rate: 0.83795, falsch-positiv Rate: 0.16302, Relevanz: 0.76081.

Bei dem Datensatz *114k* liefert somit die lineare SVM das beste Ergebnis. Die gleiche Auswertung wird an den beiden anderen 3D-Datensätzen vorgenommen.

In Abbildung 5.15 wird der Datensatz *47k1* mit einer linearen SVM bewertet. Dabei werden von den 47 124 Situationen 9122 als Stützvektoren ausgewählt. Das entspricht einem Anteil von 19,4 %. Bei der anschließenden Validierung in Abbildung 5.16 werden 0 % der kritischen Situationen richtig erkannt und 0 % der unkritischen Situationen werden fälschlicherweise als kritisch eingestuft.

Dies entspricht einer Relevanz der SVM von 100 %. Bei dieser SVM ist zu beachten, dass absolut jede Situation als unkritisch eingestuft wurde. Dadurch liegt mit dieser SVM kein verwendbarer Klassifikator vor. Die Bewertung der Relevanz mit 1(100 %) ist lediglich auf die Definition des Sonderfalls, dass Zähler und Nenner Null sind zurückzuführen. An diesem Beispiel ist ersichtlich, dass die Reduktion der Klassifizierungsleistung auf einen einzelnen Kennwert auch zu Fehleinschätzungen führen kann, wenn man die zugrunde liegenden Werte außer Acht lässt.

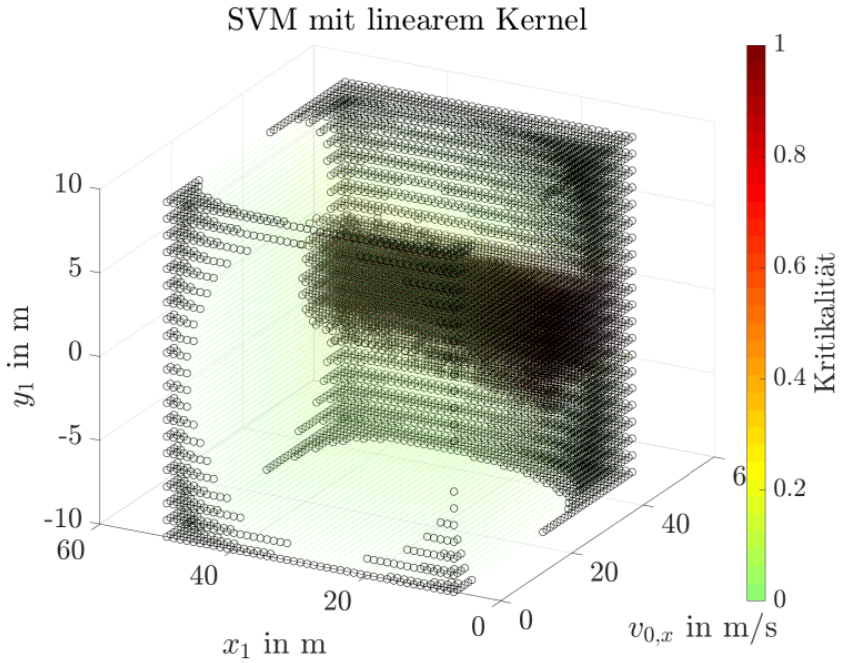

Abbildung 5.15: Die gelernten Stützvektoren sind als schwarze Kreise in den Situationsraum eingezeichnet. Die einzelnen Situationen sind nach ihrer Kritikalität eingefärbt. Die Auswertung bestätigt die optische Annahme, dass dieser Datensatz nicht linear getrennt werden kann.

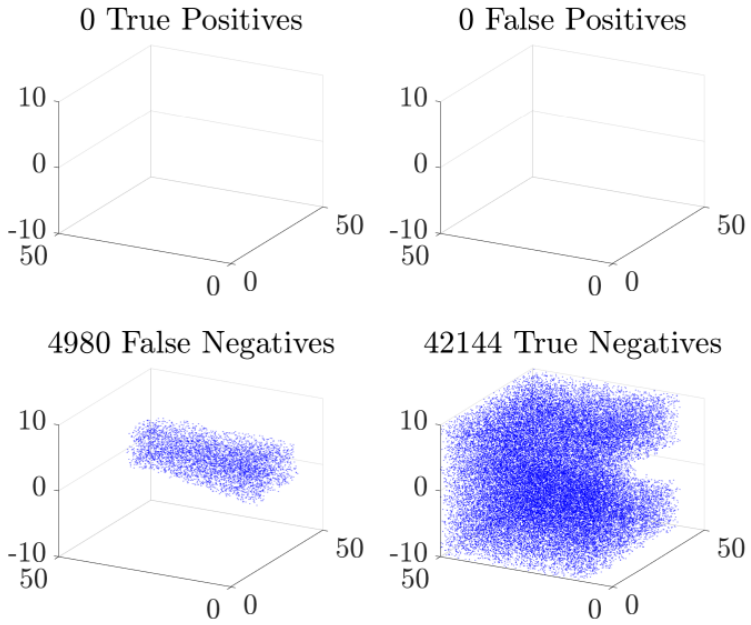

Abbildung 5.16: Die einzelnen Darstellungen zeigen jeweils die Einstufung durch die gelernte SVM auf einem Testdatensatz. Die SVM kann keine Information aus den Daten lernen und bewertet alle Situationen als unkritisch. Richtig-positiv Rate: 0, falsch-positiv Rate: 0, Relevanz: 1.

In Abbildung 5.17 wird der Datensatz *47k1* mit einer RBF-Kernel SVM bewertet. Dabei werden die Daten in ihrem originalen Wertebereich belassen. Hier werden von den 47 124 Situationen 1388 als Stützvektoren ausgewählt. Das entspricht einem Anteil von 2,9 %. Bei der anschließenden Validierung in Abbildung 5.18 werden 68 % der kritischen Situationen richtig erkannt und 2,6 % der unkritischen Situationen werden fälschlicherweise als kritisch eingestuft. Dies entspricht einer Relevanz der SVM von 75,9 %. Die relative Bewertung dieser SVM fällt nicht sehr gut aus, allerdings zeigt die optische Überprüfung, dass Stützvektoren an den richtigen Stellen, am Rande des Kritischen Bereichs, ausgewählt werden.

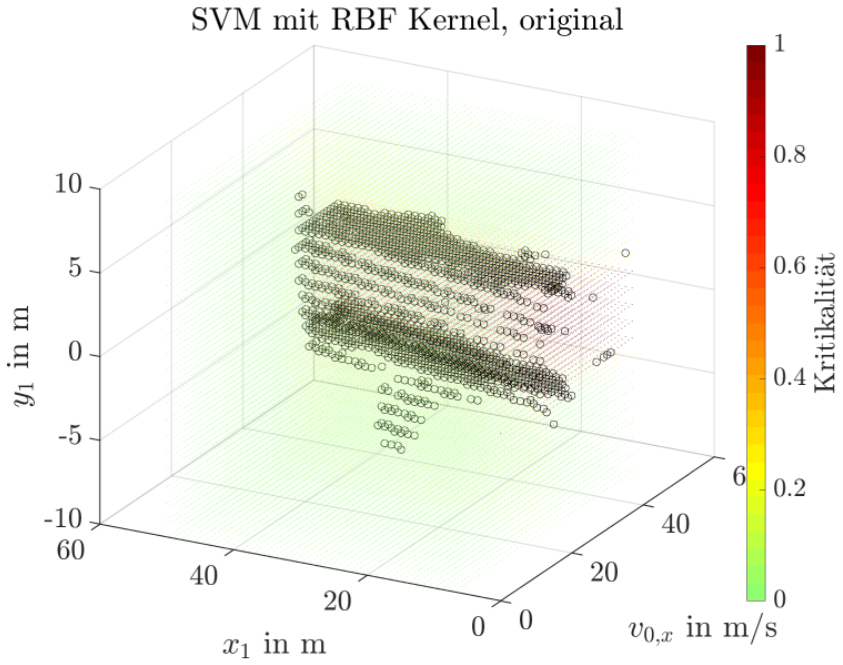

Abbildung 5.17: Die gelernten Stützvektoren sind als schwarze Kreise in den Situationsraum eingezeichnet. Die einzelnen Situationen sind nach ihrer Kritikalität eingefärbt.

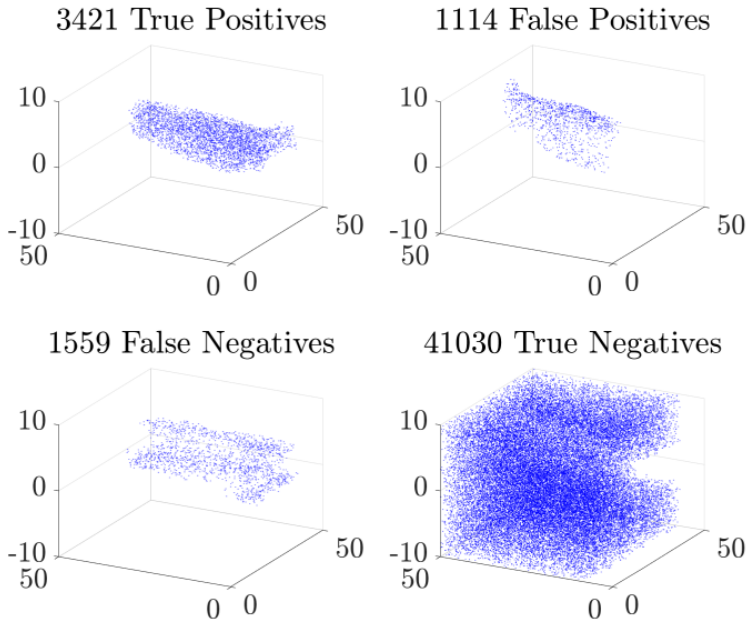

Abbildung 5.18: Die einzelnen Darstellungen zeigen jeweils die Einstufung durch die gelernte SVM auf einem Testdatensatz. Richtig-positiv Rate: 0.6803, die falsch-positiv Rate: 0.025678, und die Relevanz: 0.75935.

In Abbildung 5.19 wird der Datensatz *47k1* mit einer RBF-Kernel SVM bewertet. Die Daten werden hier jedoch in einen normierten Wertebereich überführt. Hier werden von den 47 124 Situationen 2334 als Stützvektoren ausgewählt. Das entspricht einem Anteil von 4,95 %. Bei der anschließenden Validierung in Abbildung 5.20 werden 51,7 % der kritischen Situationen richtig erkannt und 10,6 % der unkritischen Situationen werden fälschlicherweise als kritisch eingestuft. Dies entspricht einer Relevanz der SVM von 36,6 %. Die relative Bewertung dieser SVM fällt deutlich schlechter aus, als bei der Betrachtung im originalen Wertebereich, obwohl die Stützvektoren ebenso am Rande des Kritischen Bereichs ausgewählt werden.

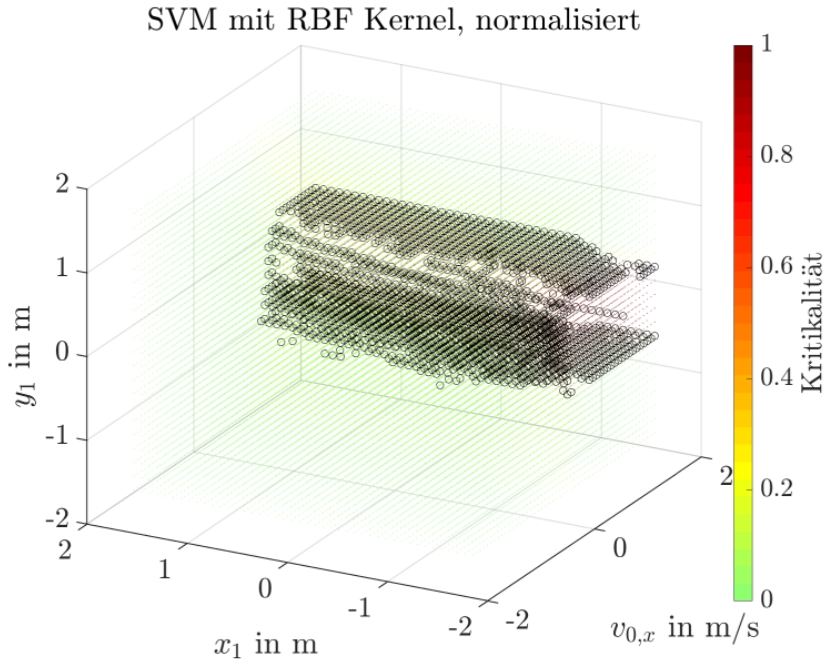

Abbildung 5.19: Die gelernten Stützvektoren sind als schwarze Kreise in den Situationsraum eingezeichnet. Die einzelnen Situationen sind nach ihrer Kritikalität eingefärbt.



Abbildung 5.20: Die einzelnen Darstellungen zeigen jeweils die Einstufung durch die gelernte SVM auf einem Testdatensatz. Richtig-positiv Rate: 0.51715, falsch-positiv Rate: 0.10661, Relevanz: 0.36619.

Der letzte 3D-Datensatz wird ebenso ausführlich untersucht, um später die Ergebnisse auf dem 5D-Datensatz richtig einordnen zu können.

In Abbildung 5.21 wird der Datensatz *47k2* mit einer linearen SVM bewertet. Dabei werden von den 47 124 Situationen 9156 als Stützvektoren ausgewählt, das entspricht einem Anteil von 19,4 %. Bei der anschließenden Validierung in Abbildung 5.22 werden 43,7 % der kritischen Situationen richtig erkannt, und 2,1 % der unkritischen Situationen werden fälschlicherweise als kritisch eingestuft. Dies entspricht einer Relevanz der SVM von 70,9 %. Bei dieser SVM ist zu beachten, dass durch die schiere Anzahl an Stützvektoren ein dennoch passables Ergebnis erzielt wurde. Diese Klassifizierungsleistung beruht jedoch eher auf einem Auswendiglernen der kritischen Situationen, als auf einer Erkennung der dafür verantwortlichen Parameterwerte.

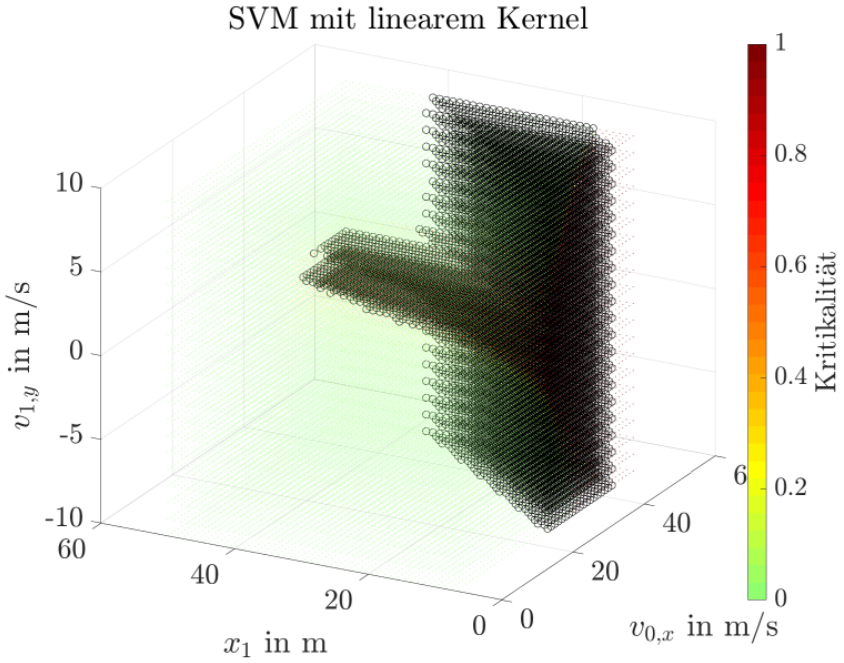

Abbildung 5.21: Die gelernten Stützvektoren sind als schwarze Kreise in den Situationsraum eingezeichnet. Die einzelnen Situationen sind nach ihrer Kritikalität eingefärbt.

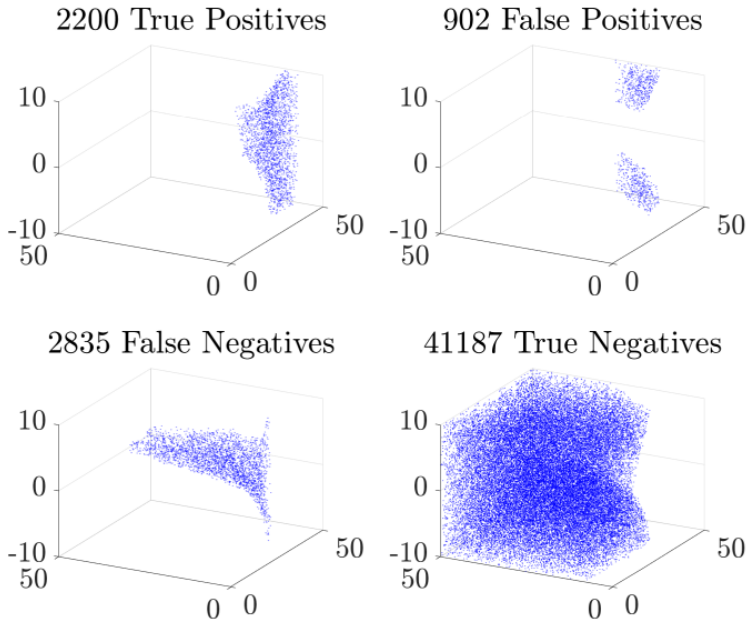

Abbildung 5.22: Die einzelnen Darstellungen zeigen jeweils die Einstufung durch die gelernte SVM auf einem Testdatensatz. Richtig-positiv Rate: 0.43694, falsch-positiv Rate: 0.021431, Relevanz: 0.70922.

In Abbildung 5.23 wird der Datensatz *47k2* mit einer RBF-Kernel SVM bewertet. Dabei werden die Daten in ihrem originalen Wertebereich belassen. Hier werden von den 47 124 Situationen 451 als Stützvektoren ausgewählt. Das entspricht einem Anteil von 0,96 %. Bei der anschließenden Validierung in Abbildung 5.24 werden 96,7 % der kritischen Situationen richtig erkannt und 2,6 % der unkritischen Situationen werden fälschlicherweise als kritisch eingestuft. Dies entspricht einer Relevanz der SVM von 97,8 %. Auf diesem Datensatz liefert die SVM eines der besten Ergebnisse, trotz des nicht trivialen kritischen Bereichs. Besser schneidet nur die lineare SVM auf dem *114k*-Datensatz ab, dort aber vorrangig des einfachen Bereichs wegen.

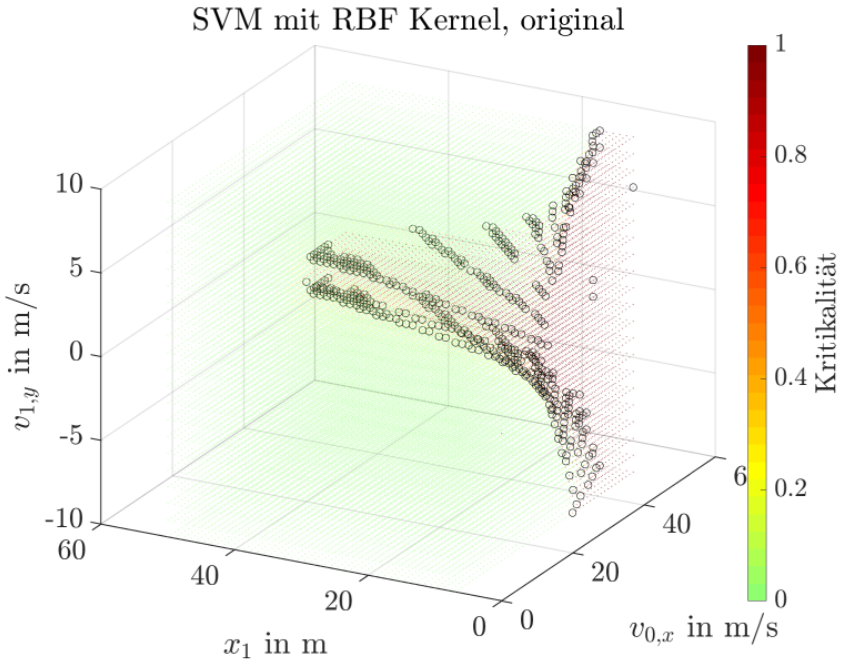

Abbildung 5.23: Die gelernten Stützvektoren sind als schwarze Kreise in den Situationsraum eingezeichnet. Die einzelnen Situationen sind nach ihrer Kritikalität eingefärbt.

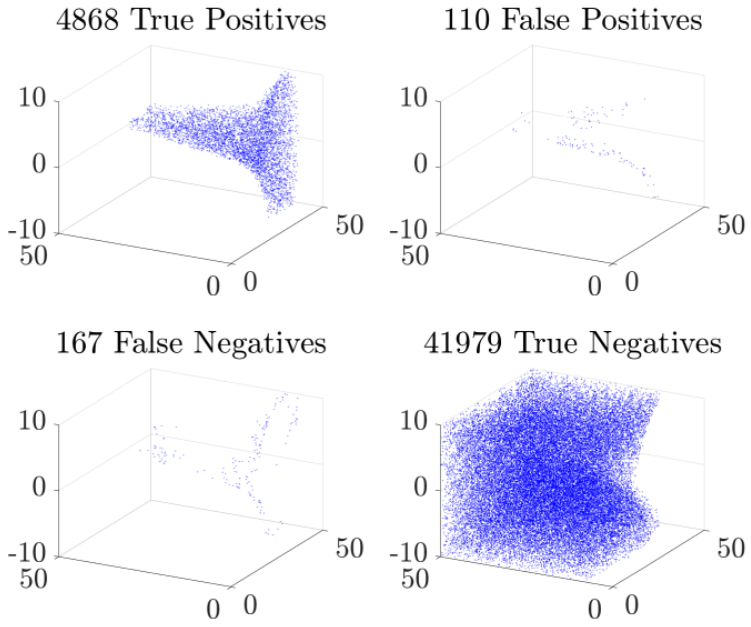

Abbildung 5.24: Die einzelnen Darstellungen zeigen jeweils die Einstufung durch die gelernte SVM auf einem Testdatensatz. Richtig-positiv Rate: 0.96683, falsch-positiv Rate: 0.0026135, Relevanz: 0.9779.

In Abbildung 5.25 wird der Datensatz *47k2* mit einer RBF-Kernel SVM bewertet. Die Daten werden hier jedoch in einen normierten Wertebereich überführt. Hier werden von den 47 124 Situationen 657 als Stützvektoren ausgewählt. Das entspricht einem Anteil von 1,39 %. Bei der anschließenden Validierung in Abbildung 5.26 werden 24,2 % der kritischen Situationen richtig erkannt und 11,2 % der unkritischen Situationen werden fälschlicherweise als kritisch eingestuft. Dies entspricht einer Relevanz der SVM von 20,5 %. Die relative Bewertung dieser SVM fällt deutlich schlechter aus, als bei der Betrachtung im originalen Wertebereich, obwohl die Stützvektoren ebenso am Rande des Kritischen Bereichs ausgewählt werden.

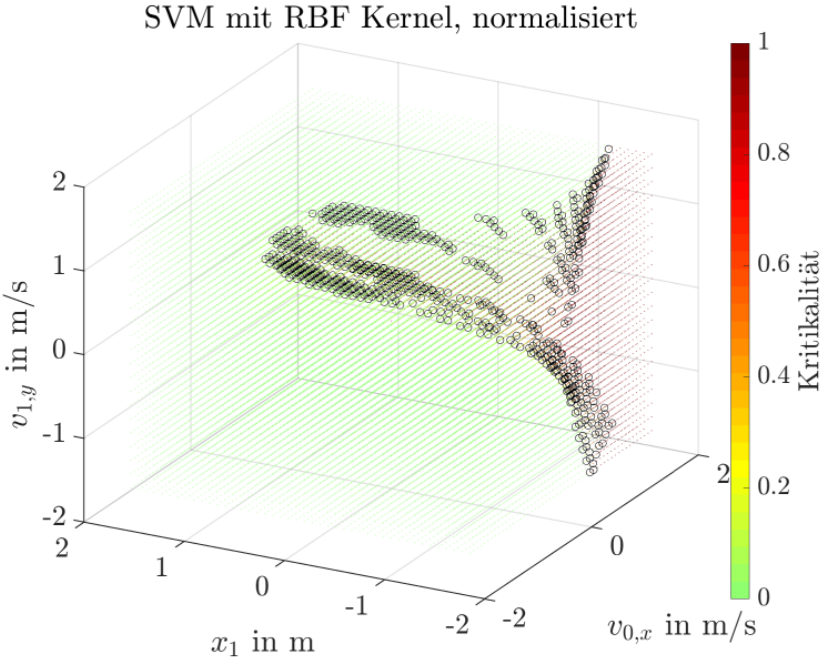

Abbildung 5.25: Die gelernten Stützvektoren sind als schwarze Kreise in den Situationsraum eingezeichnet. Die einzelnen Situationen sind nach ihrer Kritikalität eingefärbt.



Abbildung 5.26: Die einzelnen Darstellungen zeigen jeweils die Einstufung durch die gelernte SVM auf einem Testdatensatz. Richtig-positiv Rate: 0.2423, falsch-positiv Rate: 0.11255, Relevanz: 0.2048.

Aus den Abbildungen 5.9 bis 5.26 ist erkennbar, dass je nach Datensatz und Parameter unterschiedlich gute Ergebnisse erreichbar sind. Die Ergebnisübersicht der 3D-Datensätze befinden sich in Tabelle 5.4.

Tabelle 5.4: Zusammenfassung der Ergebnisse der 3D-Datensätze

Datensatz	SVM Kernel	Relevanz	Anteil Stützvektoren	Abbildung
114k	linear	99,7 %	0,88 %	5.10
114k	RBF, orignal	90,8 %	1,4 %	5.12
114k	RBF, normiert	76,1 %	0,94 %	5.14
47k1	linear	100 %	19,4 %	5.16
47k1	RBF, orignal	75,9 %	0,29 %	5.18
47k1	RBF, normiert	36,6 %	4,95 %	5.20
47k2	linear	70,9 %	19,4 %	5.22
47k2	RBF, orignal	97,8 %	0,96 %	5.24
47k2	RBF, normiert	20,5 %	1,39 %	5.26

Insgesamt waren die Ergebnisse bei allen Datensätzen mit dem RBF-Kernel im originalen Wertebereich am besten. Der dritte Situationsraum (*47k2*) konnte mit einer SVM mit RBF-Kernel auf den originalen Parametern sehr gut charakterisiert werden. Der gleiche Datensatz konnte mit einem linearen Kernel jedoch schlecht gelernt werden, trotz einer bedeutend größeren Zahl an Stützvektoren. Daraus lässt sich schließen, dass eine hohe Anzahl an Stützvektoren bedeutet, dass mit der SVM keine einfache Vorschrift oder Struktur gefunden werden konnte, anhand derer die Situationen unterschieden werden können. Die hohe Anzahl an Stützvektoren kommt einem Auswendiglernen der kritischen Situationen gleich. Daher kann diese SVM unbekannte Situationen nur schlecht klassifizieren.

In diesem Abschnitt wurde zum einen die Auswertemethodik mittels SVM und die Bewertung selbiger aufgezeigt. Zum anderen wurden die Ergebnisse für ein besseres Verständnis ausführlich illustriert. Die Datengrundlage waren die in Abschnitt 4.6 vorgestellten 3D-Datensätze, wodurch die grafische Darstellung möglich war. Für das Training wurde jeweils eine gerasterte Version der Datensätze als Trainingsdatensatz verwendet und eine zufällig gezogene Version als Validierungsdatensatz.

5.3.2 Auswertung der 5D-Datensätze

Nachdem das Einlernen einer erfolgreichen SVM auf den 3D-Datensätzen gelungen ist, werden als nächstes die 5D-Datensätze ausgewertet. Diese sind interessanter, da sie komplexere Situationen beinhalten, allerdings auch nicht einfach zu visualisieren, da mehr als drei Dimensionen unhandlich darzustellen sind.

Wie bei den 3D-Datensätzen werden bei den 5D-Datensätzen zunächst auf jedem Datensatz eine SVM mit RBF-Kernel trainiert. Hierbei werden acht verschiedene Hyperparametersätze verwendet, welche sich in *KernelScale* und *BoxConstraint* unterscheiden. Durch die Kombination von sieben Datensätzen mit acht Hyperparametersätzen werden insgesamt 56 verschiedene SVM trainiert. Anschließend wird jede davon mit einem gemeinsamen Validierungsdatensatz überprüft. Um die Leistung der SVMs zu bewerten, werden die Kenngrößen F-Maß (F_1), Genauigkeit und *Area Under the Curve* (AUC) berechnet:

$$F_1 = \left(\frac{\text{Sensitivität}^{-1} + \text{Relevanz}^{-1}}{2} \right)^{-1} \tag{5.1}$$

$$\text{Genauigkeit} = \frac{TP + TN}{\text{Total}} \tag{5.2}$$

$$AUC = 0.5 \cdot (1 - FPR + TPR) \tag{5.3}$$

Die AUC kann direkt berechnet werden, da jede SVM einen bestimmten Arbeitspunkt in der *Receiver-Operating-Characteristic* (ROC)-Darstellung hat (Abbildung 5.27). Daher berechnet sich die Fläche als Viereck aus den Punkten $(0, 0)$, $(1, 0)$, $(1, 1)$ und (FPR, TPR), dem Punkt der die SVM beschreibt.

In Tabelle 5.5 sind die Ergebnisse über die Anzahl der Situationen und über die verwendeten Hyperparameter eingetragen. Hierbei sind die jeweils besten Werte der drei Bewertungsmethoden in einer dickeren Schriftstärke **hervorgehoben**.

Tabelle 5.5: Ergebnisse der trainierten SVMs als F-Maß, Genauigkeit und AUC, jeweils in dieser Reihenfolge untereinander pro Feld. In den Spalten stehen die verschiedenen Datensätze, in den Zeilen die verwendeten Hyperparameter.

Kernel Scale	*Box Constraint*	Datensätze						
		13k	36k	73k	85k	143k	176k	212k
auto	100	0,806 0,955 0,912	0,858 0,968 0,927	0,867 0,970 0,935	0,863 0,970 0,932	0,897 0,978 0,939	0,890 0,976 0,935	0,891 0,976 0,935
auto	1	0,817 0,960 0,903	0,862 0,970 0,917	0,887 0,975 0,940	0,882 0,974 0,937	0,896 0,978 0,930	0,902 0,979 0,936	0,893 0,977 0,930
auto	∞	0,805 0,955 0,911	0,855 0,968 0,926	0,877 0,972 0,942	0,871 0,971 0,937	0,898 0,978 0,940	0,892 0,977 0,936	0,882 0,975 0,930
auto*	$\infty^\star$	0,770 0,951 0,864	0,841 0,965 0,914	0,841 0,965 0,910	0,836 0,965 0,907	0,875 0,973 0,922	0,868 0,972 0,917	0,866 0,972 0,917
0,1	∞	0,000 0,891 0,500	0,000 0,891 0,500	0,000 0,891 0,500	0,000 0,891 0,500	0,000 0,891 0,500	0,000 0,891 0,500	0,000 0,891 0,500
10	∞	0,811 0,957 0,912	0,880 0,974 0,939	0,911 0,980 0,961	0,914 0,981 0,964	0,941 0,987 0,959	0,938 0,987 0,957	0,939 0,987 0,957
20	∞	0,839 0,965 0,908	0,927 0,984 0,966	0,949 **0,989** **0,978**	0,941 0,987 **0,978**	**0,950** **0,989** 0,963	0,928 0,985 0,950	0,936 0,986 0,955
30	∞	0,844 0,966 0,910	0,933 0,985 0,971	0,892 0,976 0,946	0,931 0,985 0,970	0,859 0,970 0,911	0,846 0,968 0,902	0,869 0,971 0,932

*: Diese SVM nutzt zusätzlich eine Normalisierung der Datenpunkte, wodurch im direkten Vergleich zur Zeile darüber eine Verschlechterung der Ergebnisse eintritt.

Es zeigt sich, dass mit den Hyperparametern $(20, \infty)$ jeweils die besten Ergebnisse erzielt wurden. Auf Basis des F-Maßes lässt sich auf dem *143k*-Datensatz die beste SVM trainieren (F-Maß = 0,95). Unter Verwendung der Genauigkeit liefern die Datensätze *73k* und *143k* die besten SVMs (Genauigkeit = 0,989). Die auf den Datensätzen *73k* und *85k* trainierten SVMs erzielen die höchste AUC (AUC = 0,978). Zusätzlich verteilen sich die besten Ergebnisse über die drei mittelgroßen Datensätze. Erwartungsgemäß hätte man auf Grund der höheren Informationsdichte die besten Ergebnisse auf den größten Datensätzen vermutet. Dies könnte allerdings daran liegen, dass die Datensätze unterschiedlich gerastert sind und die mittelgroßen für die SVMs bessere Situationen beinhalten.

Des Weiteren ist bei der Zeile mit *KernelScale* 0,1 zu beachten, dass hier keine der mit diesem Hyperparametersatz trainierte SVM kritische Situationen erkennen kann. Daher befänden sich diese in Abbildung 5.27 im Punkt $(0, 0)$, welcher aus Darstellungsgründen nicht eingezeichnet ist. Da bei diesen SVMs jede Situation als unkritisch eingestuft wird, gibt die Genauigkeit den Anteil der unkritischen Situationen am Validierungsdatensatz an. Dieser ist mit 89,1 % sehr hoch, liegt jedoch an der zufälligen Auswahl an Situationen. Dies zeigt, dass der Anteil an kritischen Situationen im untersuchten Situationsraum relativ gering ist.

In Abbildung 5.27 sind die richtig-positiv Rate über der falsch-positiv Rate der trainierten SVMs abgetragen. Diese ROC-Darstellung bietet die Möglichkeit die Abstraktionsfähigkeit eines Klassifikators visuell zu überprüfen. Das Optimum liegt in dieser Ansicht in der linken oberen Ecke, im Punkt $(0, 1)$. Dort würden alle kritischen Situationen richtig erkannt werden und keine unkritische Situation fälschlicherweise als kritisch deklariert. Hierbei wird zur besseren Übersicht ein anderes Symbol pro Hyperparametersatz verwendet. Die unterschiedlichen Datensätze lassen sich daher aus der Abbildung nicht ablesen.

Die drei besten SVMs haben jeweils auch nur einen geringen Anteil der Situationen als Stützvektoren benötigt, wodurch eine Charakterisierung des Situationsraums verdeutlicht wird. Die daraus resultierende geringe absolute Anzahl an Stützvektoren lässt sich gut als Situationskatalog für Tests verwenden. Die Werte finden sich zusammengefasst in Tabelle 5.6. Als Fazit lässt sich anmerken, dass die Ergebnisse der meisten SVM sehr gut waren, auch wenn hier nur die besten herausgehoben wurden.

Der Hauptgrund für die Verwendung einer SVM als Auswertemethode liegt in der Berechnung der Stützvektoren. Diese können als konkrete Testsituationen zur Überprüfung automatisierter Fahrfunktionen herangezogen werden. Daher werden die Stützvektoren in den folgenden Abbildungen in ihrer Eigenschaft als Situation dargestellt. Die verschiedenen Situationen werden übereinander eingezeichnet, wobei für eine bessere Übersicht jeweils nur 150 Situationen verwendet werden. Die Abbildun-

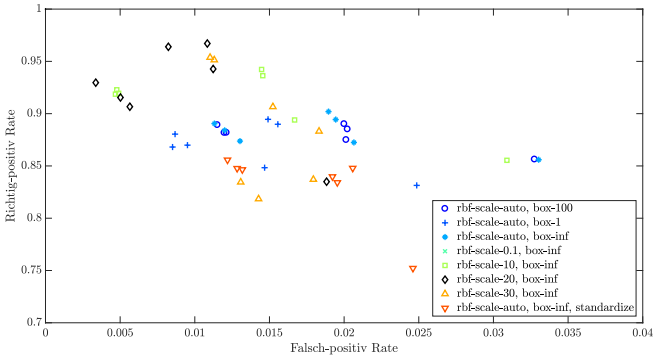

Abbildung 5.27: Übersicht der trainierten SVMs in der ROC-Darstellung. Übernommen und angepasst mit Erlaubnis aus [SD18] © 2018 IEEE

gen sind analog zu denen in Abschnitt 4.6 so aufgebaut, dass sich das Ego-Fahrzeug stets im Punkt $(0, 0)$ befindet. Für jede Situation wird das andere Fahrzeug zusätzlich eingezeichnet, wodurch insgesamt 151 Fahrzeuge in einer Abbildung dargestellt sind. Eine einzelne Situation enthält jedoch stets zwei Fahrzeuge die zueinander untersucht werden.

In Abbildung 5.28 fällt eine Häufung der Fahrzeuge direkt vor dem Ego-Fahrzeug auf. Daraus lässt sich ableiten, dass dieser Bereich einen großen Einfluss auf die Kritikalität einer Situation hat. Zusätzlich sind die Fahrzeuge oben und unten in der Abbildung nach innen ausgerichtet. Daraus lässt sich schließen, dass Situationen entscheidend sind, bei denen sich die Fahrzeuge aufeinander zubewegen.

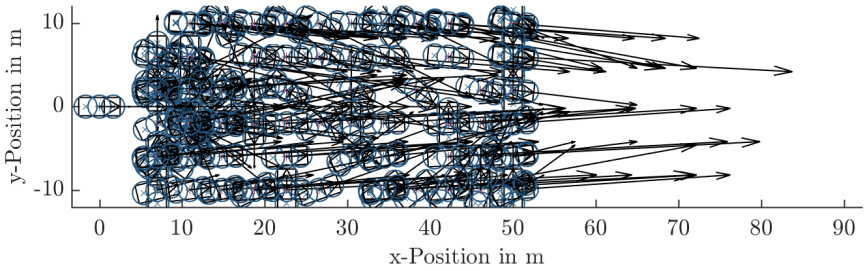

Abbildung 5.28: Übereinander abgebildet sind 150 der 1032 Stützvektoren der SVM mit *KernelScale* 20 und *BoxConstraint* ∞ auf dem *73k* Datensatz.

Tabelle 5.6: Übersicht der besten SVMs mit den erreichten Werten und Stützvektoranzahl.

Kernel Scale 20	*Box Constraint* ∞	Datensätze 73k	85k	143k
F-Maß		0,949	0,941	0,950
Genauigkeit		0,989	0,987	0,989
AUC		0,978	0,978	0,963
Stützvektoren				
Absolut		1032	1401	3030
Relativ		1,4 %	1,7 %	2,1 %

In Abbildung 5.29 stellt sich ein ähnliches Bild dar. Eine Häufung der Fahrzeuge vor dem Ego-Fahrzeug und nach innen gerichtete äußere Fahrzeuge.

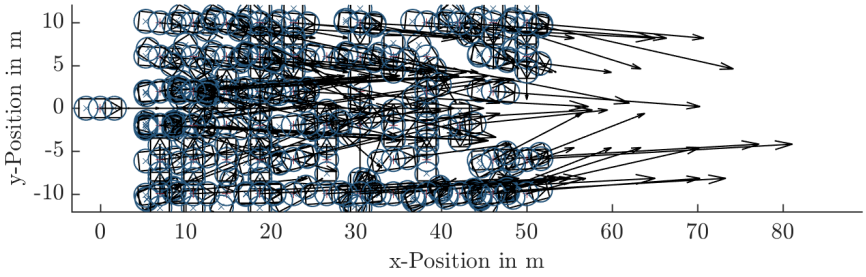

Abbildung 5.29: Übereinander abgebildet sind 150 der 1401 Stützvektoren der SVM mit *KernelScale* 20 und *BoxConstraint* ∞ auf dem *85k* Datensatz.

In Abbildung 5.30 sieht die Verteilung leicht anders aus, auch wenn prinzipiell ebenso eine Häufung der Fahrzeuge vor dem Ego-Fahrzeug und nach innen gerichtete äußere Fahrzeuge auftreten. Da bei diesem Datensatz allerdings deutlich mehr Stützvektoren zur Verfügung stehen, kann diese Darstellung auch dem relativ geringen Anteil an eingezeichnet Situation geschuldet sein.

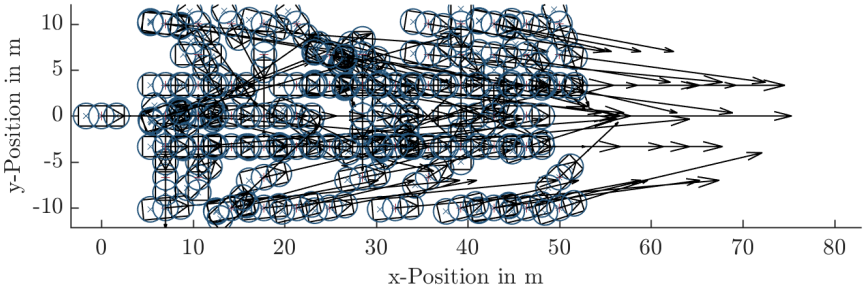

Abbildung 5.30: Übereinander abgebildet sind 150 der 3030 Stützvektoren der SVM mit *KernelScale* 20 und *BoxConstraint* ∞ auf dem *143k* Datensatz.

5.4 Diskussion

5.4.1 Kritikalitätsgrenze

Die Entscheidung, ab welcher Kritikalität eine Situation als *kritisch* oder *unkritisch* bezeichnet wird, erfolgt nicht auf experimenteller Basis, sondern bewusst aus Überlegungen heraus. Zunächst ist die Unterscheidung notwendig, um verschiedene Klassen von Situationen zu erstellen, welche auf ihre Charakteristiken untersucht werden können. Hier wurden im vergangenen Kapitel GPLVM und SVM ausführlich analysiert und festgestellt, dass durch Anwendung von GPLVM leider keine zielführenden Ergebnisse erhalten werden konnten. Durch Verwendung von SVMs hingegen wurde eine Charakterisierung ermöglicht. Dabei wurde als Grenze stets 50 % Kritikalität vorgegeben, es wäre allerdings auch jeder andere Wert zwischen 0 % bis 100 % möglich gewesen. Dabei wären im Falle der SVM wahrscheinlich andere Stützvektoren berechnet worden, die Aussage über diese wäre aber die gleiche geblieben. Die konkrete Wahl der Grenze hängt damit auch stark von der verwendeten Bewertungsmethode ab. Im betrachteten Fall geschieht dies über die Kollisionswahrscheinlichkeit bei zufälliger Episodengenerierung. Hier kann argumentiert werden, dass eine Situation solange unkritisch ist, wie noch kollisionsfreie Episoden gefunden werden können. In diesem Fall würde man die Grenze eher bei 99 % setzen. Theoretisch kann auch die Aussage, dass eine Situation kritisch ist, sobald eine Kollision möglich ist, herangezogen werden. Allerdings würde dann jede Situation, bei der mehrere Fahrzeuge nicht sehr weit entfernt sind, als kritisch eingestuft werden, wodurch diese Einteilung unbrauchbar würde.

5.4.2 Stützvektoren

Die Verwendung der SVM hat zwei Vorteile. Zum einen konnte damit gezeigt werden, dass es möglich ist eine Struktur im Situationsraum zu finden, welche für die Einschätzung neuer Situationen, ohne die aufwendigere Berechnung über Episodengenerierung, verwendet werden kann. Diese kann auch mit anderen Verfahren aus dem Bereich des maschinellen Lernens erreicht werden. Eine SVM liefert jedoch zusätzlich auch Stützvektoren, in diesem Fall konkrete Situationen, die zu dieser Einschätzung beitragen. Diese können, wie in der Auswertung angemerkt, als Situationskatalog dienen. Aus diesem können Testsituationen gezogen werden, welche beispielsweise in einem Simulator zur Überprüfung der Fahrfunktionen genutzt werden.

Diese Situationen sind dabei nicht an sich kritisch, sondern führen, je nach ausgeführter Episode, in eine kritische Situation. Somit sollte die entwickelte Fahrfunktion stets eine unkritische Situation erzeugen.

Kapitel 6

Auswertung von Realdaten

In den vorangegangenen Kapiteln wurden ausschließlich Simulationsdaten verwendet. Die Auswahl an Situationen, hauptsächlich die Grenzen für die Positionierung und Zustände der Fahrzeuge, erfolgte durch praktische Überlegungen. In diesem Kapitel werden Situationen aus Aufzeichnungen aus dem realen Straßenverkehr erstellt, um diese in den Kontext der Simulation bringen zu können. Dieser Vergleich zeigt, wie sich die beobachteten Situationen in den entworfenen Situationsraum einbringen. Dabei ist besonders interessant, ob reale Situationen in kritischen Bereichen liegen oder nicht. Zunächst werden dafür die Aufnahmen aufbereitet, um das für die vorgestellte Methodik benötigte Datenformat zu erhalten.

6.1 Ursprung und Art der Aufnahmen

Am Institut für Mess-, Regel- und Mikrotechnik der Universität Ulm stehen zwei Fahrzeuge für die Erprobung des automatisierten Fahrens zur Verfügung [KNW+15]. Zur Perzeption verfügen die Versuchsträger über ein Differentielles Globales Positionierungssystem (*Differential Global Positioning System*) (DGPS) zur hoch genauen Bewegungs- und Positionsbestimmung, mehrere Lidare, Radare und Kameras zur Wahrnehmung anderer Objekte und Verkehrsteilnehmer. Zusätzlich zum automatisierten Fahrbetrieb können die Testfahrzeuge auch für die Aufnahme von Fahrsequenzen verwendet werden, welche für die Entwicklung der benötigten Algorithmen abseits der Straße zur Verfügung stehen. Zum Vergleich der in dieser Arbeit vorgestellten Methoden mit real eingefahrenen Sequenzen wurden die am Institut vorhandenen Aufnahmen systematisch ausgewertet.

Die verwendeten Aufnahmen, welche durch verschiedene Mitarbeiter des Instituts in den Jahren 2014 bis 2017 aufgenommen wurden, sind über das Programm *Automotive Data and Time-Triggered Framework* (ADTF) nutzbar.

6.2 Vorbereitung der Aufnahmen

Für die angestrebte Auswertung werden Daten in Form von Situationen benötigt. Die Fahrsequenzen liegen zunächst als Datenstrom vor, der die Daten aller aufgenommenen Sensoren aufweist. Für die Extraktion werden zunächst die am Institut vorhandenen Trackingalgorithmen [RVVD14] verwendet, um Fahrzeuge in den Sequenzen erkennen und verfolgen zu können. Nach diesem ersten Vorverarbeitungsschritt kann zu jedem aufgenommenen Zeitpunkt eine Situation erstellt werden. Oft existieren jedoch mehrere Fahrzeuge um das Ego-Fahrzeug herum, weshalb eine Auswahl aus diesen getroffen werden muss.

6.3 Auswahl der betrachteten Fahrzeuge

Eine Situation, wie sie in dieser Arbeit definiert und verwendet wird, benötigt eine feste Anzahl an Fahrzeugen N. Sind in einer Messung allerdings K Fahrzeuge vorhanden, existieren $\binom{K}{N}, K \geq N$ mögliche Situationen in dieser Messung. Theoretisch ist es somit möglich, die Anzahl der gewonnenen Situationen um ein Vielfaches zu erhöhen. In der Praxis werden allerdings nicht alle gemessenen Objekte gleich gut geeignet sein. Zusätzlich bietet es sich an, das Aufnahmefahrzeug als Ego-Fahrzeug in der extrahierten Situation zu verwenden, was im Folgenden auch so gehandhabt wird. Des Weiteren wird zur Reduktion der Komplexität zunächst Augenmerk auf Situationen mit zwei Fahrzeugen gelegt, wodurch auch die Kompatibilität mit den in Kapitel 4 erstellten Datensätzen gewährleistet ist. Da die Messergebnisse für Fahrzeuge vor dem Aufnahmefahrzeug besser sind und vorausfahrende Fahrzeuge einen größeren Einfluss auf das eigene Verhalten haben, wird für die Situationen das nächste vorausfahrende Fahrzeug zum Ego-Fahrzeug gesucht. Zusätzlich ist es in den im realen Straßenverkehr getätigten Aufnahmen zu keinen Kollisionen gekommen, da durch die Sicherheitsfahrer ein passives Fahrverhalten umgesetzt wird, wodurch die Situationen allgemein als nicht kritisch erwartet werden.

Die extrahierten Situationen werden zwar einzeln und unabhängig voneinander mit der in Abschnitt 4.5 vorgestellten Methode bewertet, dennoch sind zeitlich aufeinander folgende Situationen besonders interessant. Diese bilden aneinandergereiht die tatsächlich aufgetretene Episode und können daher auch als Referenz aufgefasst werden. Daher wird bei der Erstellung der Situationen auch darauf geachtet, nach Möglichkeit ein Fahrzeug zu verwenden, das in anderen Situationen ebenso vorkommt. Abbildung 6.1 beschreibt die Situationsextraktion schematisch, ausgehend von den Fahrzeugaufnahmen, über die Reduktion der Messungen, bis zur Erstellung der abstrahierten Situation.

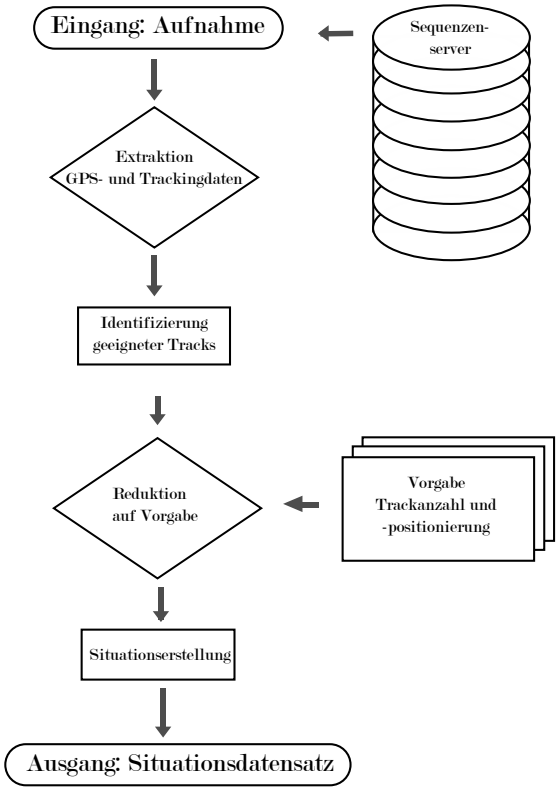

Abbildung 6.1: Schematische Darstellung der Schritte von der Fahrsequenz zum Situationsdatensatz.

6.4 Statistiken der Datensätze

Der Großteil der Situationen wurde aus den Aufnahmen des *AV-MRM-1* gewonnen. Aus 557 Sequenzen, die im Zeitraum März 2014 bis November 2017 entstanden sind, mit einer Fahrzeit von 24 h, konnten 233 Datensätze mit zusammen 664 000 Situationen erstellt werden. Sequenzen, welche nicht verwendet wurden, beinhalten entweder keine verwertbaren Fahrzeugmessungen oder genügen nicht den Anforderungen. Durch das zweite Versuchsfahrzeug *AV-MRM-2* konnten weitere 79 000 Situationen in 105 Datensätzen erstellt werden. Diese entstammen aus 181 Sequenzen, von Juli bis November 2017, welche eine Fahrzeit von knapp 4 h dokumentieren.

Die Aufnahmen stammen größtenteils aus dem Raum Ulm und beinhalten Fahrten im Stadtverkehr, auf der Landstraße und auf der Autobahn. Daher passen diese nicht vollständig auf die Annahmen aus der Aufgabenstellung, geben jedoch einen interessanten Einblick in das Auftreten realer Situationen. Zusätzlich bildet die Entwicklung der automatisierten Situationsextraktion die Grundlage auch jede zukünftige Aufnahme direkt zu bewerten. Die mittlere Geschwindigkeit der Fahrzeuge beträgt $53\,\mathrm{km\,h^{-1}}$ wobei Geschwindigkeiten von $0\,\mathrm{km\,h^{-1}}$ bis $180\,\mathrm{km\,h^{-1}}$, beziehungsweise bis $145\,\mathrm{km\,h^{-1}}$ beim Ego-Fahrzeug, vorkommen. Dabei beträgt der mittlere Abstand zum vorausfahrenden Fahrzeug 41 m in einem Bereich von 3,5 m bis 90 m. Hierbei ist zu beachten, dass es sich um den Abstand der Referenzpunkte der Fahrzeuge handelt. Fahren diese direkt hintereinander, bedeutet ein Abstand einer Autolänge, dass sie sich bereits berühren. Die in den Aufnahmen vorkommende mittlere zeitliche Lücke liegt bei 3,1 s im vorkommenden Intervall von 0,09 s bis 10 s. Bei der Berechnung wurden Zeitlücken von über 10 s nicht berücksichtigt, da der Wert für langsame Geschwindigkeiten gegen unendlich wächst. Bei den Minimal- und Maximalwerten ist zu beachten, dass eine seitliche Verschiebung der Fahrzeuge in den Situationen berücksichtigt wird, die Kritikalität also richtig berechnet wird. Durch die automatisierte Auswertung werden auch Situationen erstellt, in denen ein anderes Fahrzeug gerade überholt wird. Dadurch kommen trotz hoher Geschwindigkeiten geringe Abstände vor, da sich die Fahrzeuge seitlich versetzt bewegen.

Die beiden Minimalwerte der Abstände und der Zeitlücke in dieser Sequenz fungieren als Beispiel einer kritischen Situation. Die Aufnahme entstand während einer Autobahnfahrt, als an einem Lkw vorbeigefahren wurde. Da die Sensormessungen mehrdeutige Werte bei Lkws erzeugen, entsteht ein näheres Objekt in der Situation als eigentlich vorhanden. Die gesamte Sequenz beinhaltet 1173 Situationen, wovon zwei als Auszug in Abbildung 6.2 dargestellt sind.



(a) Anfahrt an Lkw.

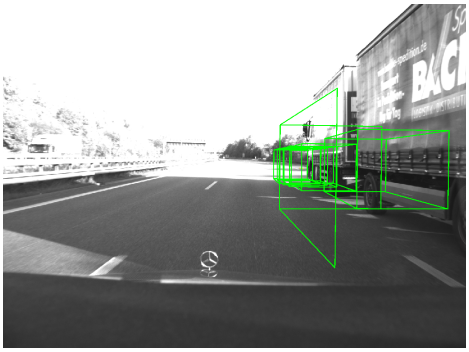

(b) Vorbeifahrt an Lkw.

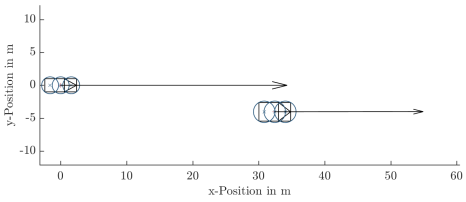

(c) Aus (a) resultierende Situation.

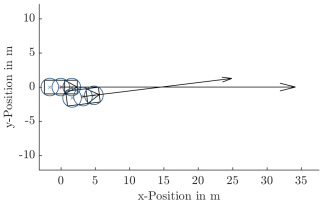

(d) Aus (b) resultierende Situation.

Abbildung 6.2: Vergleich zwischen den Videobildern (a) und (b) sowie der daraus erstellten Situationen (c) und (d). Die in der Aufnahme vorhandenen Tracks sind als grüne Boxen eingezeichnet. Die Situation in (d) ist kritisch, da der Track in (b) nach links verschoben ist und somit eine Kollision auftritt.

Diese Beispielbilder stellen ausdrücklich keine Bewertung des Trackings dar, es wird ausschließlich veranschaulicht, warum kritische Situationen im Datensatz vorkommen können, obwohl keine Kollisionen stattgefunden haben. Zusätzlich können kritische Situationen entstehen, wenn zügig an ein haltendes Fahrzeug herangefahren wird. In der Realität wird der Fahrer rechtzeitig anhalten, durch die zufällige Episodengenerierung ist das Auftreten einer Kollision hingegen öfters zu beobachten.

6.5 Darstellung im Situationsraum

Die Extraktion der Situationen aus Aufnahmen des realen Straßenverkehrs ermöglicht die Einordnung in den vorher definierten Situationsraum aus Kapitel 4.6. Dabei wird untersucht, wie tatsächliche Situationen mit simulierten Situationen zu vergleichen und welche Rückschlüsse daraus zu ziehen sind.

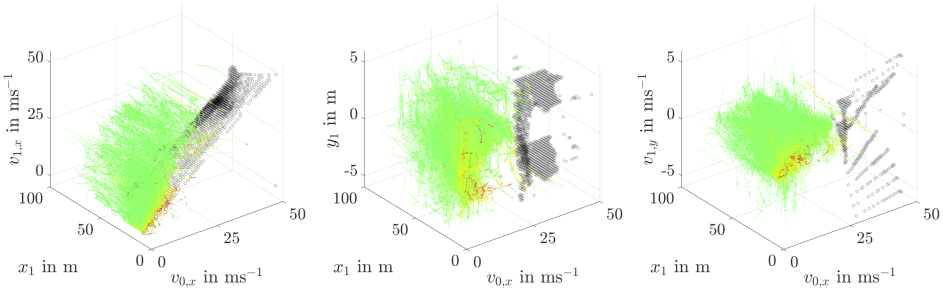

Abbildung 6.3: Visualisierung der extrahierten Situationen in 3D mit den gelernten Stützvektoren. Übernommen und angepasst mit Erlaubnis aus [SD18] © 2018 IEEE

Die drei Darstellungen in Abbildung 6.3 zeigen die aufgenommenen und bewerteten Situationen, sowie die Stützvektoren der SVM aus Kapitel 5. Da die aus Realdaten extrahierten Situationen je zwei Fahrzeuge und fünf Dimensionen besitzen, wurden diese zur Darstellung in verschiedene 3D-Unterräume eingezeichnet. Die Aufteilung der Dimensionen entspricht den Parametern der Datensätze *114k*, *47k1* und *47k2* aus Tabelle 4.3. Die Stützvektoren sind dabei aus den Abbildungen 5.11, 5.17 und 5.23 entnommen, um einen optischen Vergleich zu ermöglichen.

Hierbei sind mehrere Punkte zu beobachten:

- Durch die passive Fahrweise der Sicherheitsfahrer befindet sich der Großteil (>99 %) der Situationen im unkritischen Bereich.

- Ungefähr 0,5 % der Situationen werden als kritisch eingestuft, was sich durch die Vorbereitung der Datensätze und durch den Extraktionsprozess erklären lässt. Die durchgeführte Auswertung wurde nicht händisch auf Fehlmessungen oder Geisterobjekte überprüft. Daher können sich falsch erkannte Verkehrsteilnehmer in den Situationen wiederfinden. Werden diese bei der Situationserstellung berücksichtigt, könnte dies zu vermeintlich kritischen Situationen führen, die so gar nicht aufgetreten sind.

- Viele Situationen liegen dicht an, jedoch über der Trennebene. Dies deutet darauf hin, dass der Sicherheitsabstand stets eingehalten, aber auch nicht mehr Abstand als nötig gewährt wurde. Zur Bewertung wird der euklidische Abstand jeder Situation zum nächsten Stützvektor berechnet. Dabei ergibt sich, dass 50 % der Situationen näher als 4,9 an einem Stützvektor liegen und 70 % näher als 8,5.

- Ein Drittel der extrahierten Situationen liegt außerhalb des simulierten Bereichs. Dort hat das nächste Fahrzeug einen größeren Abstand, als bei den Situationsauswertungen als beachtenswert eingestuft wurde. Da größere Abstände in weniger kritischen Situationen resultieren, würde eine Ausdehnung des simulierten Bereichs auf die Messdaten der Vollständigkeit dienen, aber keine weiteren Erkenntnisse ermöglichen.

6.6 Interpretation der Ergebnisse

Durch den Vergleich der realen Situationen mit den simulierten ist eine Interpretation der erhaltenen Ergebnisse möglich. Einige Punkte sind schon in den Beobachtungen im vorhergehenden Abschnitt beschrieben und werden hier aufgegriffen. Es ist bekannt, dass es bei keiner der aufgenommenen Sequenzen zu einer Kollision gekommen ist. Daraus lässt sich zwar nicht schließen, dass keine gefährlichen Fahrmanöver durchgeführt wurden, aber zumindest, dass wenig kritische Situationen aufgetreten sein sollten. Ausgehend von dieser Annahme können die realen Situationen als Grundlage für unkritische Situationen genommen werden, wodurch sich ein unkritischer Bereich im Situationsraum bilden lässt. Somit wäre aus den realen Daten ein ähnlich abgetrennter Bereich im Situationsraum ableitbar, wie er von den SVM auf den simulierten Situationen berechnet wurde. Auch wenn dies für die Entwicklung und

Anwendung des Verfahrens nicht notwendig ist, werden die angenommen Intervalle der Situationsparameter durch die realen Situationen unterstützt. Da die gemessenen Situationen einen größeren unkritischen Abstandsbereich abdecken als die Simulationen, besteht in der Reichweite der Sensorik für diesen Zweck keine Einschränkung. Das Spektrum der gefahrenen Geschwindigkeiten ist allerdings geringer als in den Simulationen betrachtet. Die Aufnahmen des Ego-Fahrzeugs reichen von $0\,\mathrm{m\,s^{-1}}$ bis $40\,\mathrm{m\,s^{-1}}$, wohingegen die Simulationen von $0\,\mathrm{m\,s^{-1}}$ bis $50\,\mathrm{m\,s^{-1}}$ ausgehen. Hier müsste für detailliertere Vergleiche ein höheres Geschwindigkeitsprofil eingefahren werden. Bei den aufgenommenen Fahrzeugen erstrecken sich die beobachteten Geschwindigkeiten allerdings über den kompletten simulierten Bereich von $0\,\mathrm{m\,s^{-1}}$ bis $50\,\mathrm{m\,s^{-1}}$. In den vorhandenen Aufnahmen finden sich, glücklicherweise, keine Kollisionen und aus bereits erwähnten Gründen praktisch keine kritischen Situationen. Diese könnten allerdings bessere Aussagen über den kritischen Bereich bei realen Fahrten zulassen.

Kapitel 7

Zusammenfassung und Ausblick

7.1 Zusammenfassung

In der vorliegenden Arbeit wird ein Teilgebiet der Absicherung der Funktionssicherheit von E/E-Systemen im Kontext der ISO 26262 untersucht, die Bestimmung geeigneter Testfälle. Dazu wurde zunächst eine mathematische Formulierung zur Beschreibung von Situationen und Episoden erarbeitet. Durch die Entwicklung und Anwendung eines Kritikalitätsmaßes konnten Situationen in unterschiedliche Risikoklassen eingestuft werden. Die Abläufe wurden hierbei so entworfen, dass eine Änderung der Darstellung, der Berechnung und des Bewertungsmaßes möglich ist und sie daher für weiterführende Arbeiten angepasst werden können.

Das Hauptaugenmerk lag in dieser Arbeit nicht auf einer exakt definierten Aussage über jede einzelne Situation, sondern auf der statistischen Aussage über viele Situationen. Daher wurden im zweiten Teil der Arbeit mehrere Datensätze mit ausgewählten Situationen erstellt und mit dem vorgestellten Episodengenerierungsverfahren bewertet. Diese Daten bildeten die Grundlage für die Charakterisierung der Situationsräume, einer Repräsentation der Situationen in drei, fünf, oder n Dimensionen, je nach Anzahl der betrachteten Situationsparameter. Eine Untersuchung mittels GPLVM erzielte keine aussagekräftigen Ergebnisse, weshalb dieser Ansatz nicht weiterverfolgt wurde. Allerdings konnten erfolgreich SVMs auf den Datensätzen trainiert werden. Diese wurden mit zufällig generierten Testdatensätzen validiert. Daraus konnte die Existenz einer Struktur in den Daten abgeleitet und Rückschlüsse auf Testfälle gezogen werden. Da die von der SVM ausgewählten Stützvektoren den Situationsraum bestmöglich nach der vorgegebenen Kritikalität trennen, können diese als geeignete Testfälle angesehen werden. Diese Situationen haben die Eigenschaft, dass sie die Grenze zwischen *kritischen* und *unkritischen* Situationen bilden. Daher kann die Qualität der Fahrfunktion eines hochautomatisierten Fahrzeugs daran bemessen werden, ob es diese Testfälle stets unkritisch lösen kann.

7.2 Ausblick

Aus der Zusammenfassung lassen sich die folgenden Anregungen als Ausblick ableiten. Es existieren viele Varianten wie der Themenkomplex der FuSi bearbeitet werden kann. In dieser Arbeit wurde dazu eine mathematische Formulierung von Situationen und Episoden ausgearbeitet, mit der eine statistische Auswertung ermöglicht wird. Parallel dazu sind in der Literatur auch andere Verfahren bekannt, welche in zukünftigen Arbeiten noch detaillierter in Kombination mit dem hier vorgestellten Verfahren ausgewertet werden können. Je nach Anforderungen können beispielsweise die Episoden komplett in einer realitätsgetreuen Simulationsumgebung erstellt werden. Dadurch ließe sich jede einzelne Situation möglichst realistisch simulieren und darstellen.

Die Auswertung der Datensätze mittels SVM hat die Existenz verwendbarer Strukturen im Situationsraum gezeigt. Bei weiteren Arbeiten können dabei noch aktuellere Verfahren Anwendung finden, wie beispielsweise Neuronale Netze.

Zusätzlich ist der nächste Schritt, die ermittelten Testfälle tatsächlich in Simulationen oder Fahrversuchen umzusetzen. Dadurch wird es möglich, deren Plausibilität in aktuellen Verfahren zur Absicherung zu überprüfen.

Anhang A

Eigene Veröffentlichungen

Teile der vorliegenden Dissertation wurden im Rahmen von Vorveröffentlichungen publiziert.

Bach, Martin; Stumper, Daniel und Dietmayer, Klaus: *Deep Convolutional Traffic Light Recognition for Automated Driving.* In: *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*, Seiten 851–858, IEEE, 2018.

Hoermann, Stefan; Stumper, Daniel und Dietmayer, Klaus: *Probabilistic long-term prediction for autonomous vehicles.* In: *2017 IEEE Intelligent Vehicles Symposium (IV)*, Seiten 237–243, IEEE, 2017.

Stumper, Daniel und Dietmayer, Klaus: *Towards Criticality Characterization of Situational Space.* In: *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*, Seiten 3378–3382, IEEE, 2018.

Stumper, Daniel; Gies, Fabian; Hoermann, Stefan und Dietmayer, Klaus: *Offline Object Extraction from Dynamic Occupancy Grid Map Sequences.* In: *2018 IEEE Intelligent Vehicles Symposium (IV)*. Band 8, Seiten 389–396, IEEE, 2018.

Stumper, Daniel; Knapp, Andreas; Pohl, Martin und Dietmayer, Klaus: *Towards Characterization of Driving Situations via Episode-Generating Polynomials.* In: *Advanced Microsystems for Automotive Applications 2016*, 2016.

Akronyme

ACC	*Adaptive Cruise Control* (Abstandsregeltempomat) 1
ADAS	*Advanced Driver Assistance Systems* (Fahrerassistenzsysteme) ... 6
ADTF	*Automotive Data and Time-Triggered Framework* 93
AEB	*Autonomous Emergency Braking* (Notbremsassistent) 5
AUC	*Area Under the Curve* 85
DARPA	*Defense Advanced Research Projects Agency* 5
DGPS	Differentielles Globales Positionierungssystem (*Differential Global Positioning System*) 93
DMV	*California Department of Motor Vehicles* 6
E/E-System	Elektrik- und Elektronik-System 6
FDM	*Foresighted Driver Model* 11
FuSi	funktionale Sicherheit 8
G&R	Gefahren- und Risikoanalyse 6
GPLVM	*Gaussian Process Latent Variable Model* ..... vii, viii, 15
IDM	*Intelligent Driver Model* 10
Lkw	Lastkraftwagen 5
MC	Monte-Carlo ..... vii, 12
NHTSA	*National Highway Traffic Safety Administration* 5
Pkw	Personenkraftwagen 2
PR	*Parameter Rate* 35
PV	*Parameter Vector* 35
RBF	*Radial Basis Function* 31

ROC *Receiver-Operating-Characteristic* 85
RRT *Rapidly-exploring Random Tree* 11
RSS *Responsibility Sensitive Safety* 8

SUMO *Simulation of Urban MObility* 11
SVM *Support Vector Machine* ..... vii, viii, 15

TTB *Time-to-Brake* 12
TTC *Time-to-Collision* 12
TTX *Time-to-X* 12

WTTC *Worst-Time-to-Collision* 12

Symbolverzeichnis

Symbole

γ	Menge der kritischen Episoden
$\mathfrak{G}$	Menge der Fahrzeuggeometrien
$\mathfrak{Z}$	Zustandsmatrix der betrachteten Fahrzeuge
$\mathfrak{l}$	Zustandsbeschränkungen eines Fahrzeugs
$\mathfrak{L}$	Menge der Zustandsbeschränkungen der betrachteten Fahrzeuge
$\gamma^{\neg}$	Menge der unkritischen Episoden
$\mathbb{R}$	Menge der reellen Zahlen
$\mathcal{E}$	Episode
$\mathfrak{E}$	Episodenraum
$\mathfrak{S}$	Situationsraum
$\mathcal{S}$	Situation
ζ	Trajektorie
$\mathfrak{T}$	Kritikalitätsmaß
$\mathbb{Z}$	Menge der ganzen Zahlen

Literaturverzeichnis

[AD12] Althoff, Matthias und Dolan, J. M.: *Reachability computation of low-order models for the safety verification of high-order road vehicle models.* In: *2012 American Control Conference (ACC)*, Seiten 3559–3566, 2012.

[Alt10] Althoff, Matthias: *Reachability Analysis and its Application to the Safety Assessment of Autonomous Cars.* In: *Fakultät für Elektrotechnik und Informationstechnik*, Seite 221, 2010.

[ASB09] Althoff, Matthias; Stursberg, Olaf und Buss, Martin: *Model-based probabilistic collision detection in autonomous driving.* In: *IEEE Transactions on Intelligent Transportation Systems*, Band 10, Nr. 2, Seiten 299–310, 2009.

[BBEK11] Behrisch, Michael; Bieker, Laura; Erdmann, Jakob und Krajzewicz, Daniel: *SUMO - Simulation of Urban MObility.* In: *Iaria*, Nr. c, Seiten 55–60, 2011.

[BBK04] Broadhurst, Adrian E; Baker, Simon und Kanade, Takeo: *A prediction and planning framework for road safety analysis, obstacle avoidance and driver information.* Techn. Ber. CMU-RI-TR-04-11. Carnegie Mellon University, Pittsburgh, PA, 2004.

[BBK05] Broadhurst, Adrian; Baker, Simon und Kanade, Takeo: *Monte Carlo Road Safety Reasoning.* In: Band 1, Nr. 412, Seiten 1–6, 2005.

[BGV92] Boser, Bernhard E.; Guyon, Isabelle M. und Vapnik, Vladimir N.: *A training algorithm for optimal margin classifiers.* In: *Proceedings of the fifth annual workshop on Computational learning theory - COLT '92*, Seiten 144–152, 1992.

[BHN+95] Bando, M.; Hasebe, K.; Nakayama, A.; Shibata, A. und Sugiyama, Y.: *Dynamical model of traffic congestion and numerical simulation.* In: *Physical review. E, Statistical physics, plasmas, fluids, and related interdisciplinary topics*, Band 51, Nr. 2, Seiten 1035–1042, 1995.

[Bis06] Bishop, Christopher M: *Pattern Recognition and Machine Learning.* Band 4, 2006, Seite 738.

[BM09] Biagiotti, Luigi und Melchiorri, Claudio: *Trajectory Planning for Automatic Machines and Robots*. Springer Berlin Heidelberg, Berlin, Heidelberg, 2009.

[Bur98] Burges, Christopher J C: *A Tutorial on Support Vector Machines for Pattern Recognition*. In: *Data mining and knowledge discovery*, Band 2, Nr. 2, Seiten 121–167, 1998.

[Che54] Chebyshev, P.L.: *Théorie des mécanismes connus sous le nom de parallélogrammes*. 1854.

[DE14] Damerow, Florian und Eggert, Julian: *Predictive risk maps*. In: *17th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, Seiten 703–710, 2014.

[DE15a] Damerow, Florian und Eggert, Julian: *Balancing Risk against Utility : Behavior Planning using Predictive Risk Maps Balancing Risk against Utility : Behavior Planning using Predictive Risk Maps*. In: 2015.

[DE15b] Damerow, Florian und Eggert, Julian: *Risk-Aversive Behavior Planning under Multiple Situations with Uncertainty*. In: *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC*, Band 2015-Octob, Seiten 656–663, 2015.

[EDK15] Eggert, Julian; Damerow, Florian und Klingelschmitt, Stefan: *The Foresighted Driver Model*. In: *IEEE Intelligent Vehicles Symposium, Proceedings*, Band 2015-August, Nr. Iv, Seiten 322–329, 2015.

[EM01] Egerstedt, Magnus und Martin, Clyde F.: *Optimal trajectory planning and smoothing splines*. In: *Automatica*, Band 37, Nr. 7, Seiten 1057–1064, 2001.

[EP08] Eidehall, Andreas und Petersson, L: *Statistical threat assessment for general road scenes using Monte Carlo sampling*. In: *IEEE Transactions on Intelligent Transportation Systems*, Band 9, Nr. 1, Seiten 137–147, 2008.

[FBZS95] Franke, U.; Bottiger, F.; Zomotor, Z. und Seeberger, D.: *Truck platooning in mixed traffic*. In: *Proceedings of the Intelligent Vehicles '95. Symposium*, Seiten 1–6, 1995.

[FK15] Fagnant, Daniel J. und Kockelman, Kara: *Preparing a nation for autonomous vehicles: Opportunities, barriers and policy recommendations*. In: *Transportation Research Part A: Policy and Practice*, Band 77, Seiten 167–181, 2015.

[GBH12] Glauner, Philipp; Blumenstock, Axel und Haueis, Martin: *Effiziente Felderprobung von Fahrerassistenzsystemen*. In: *8. Workshop Fahrerassistenzsysteme*, Seiten 5–14, 2012.

[GHL14] Gillen, Christoph; Hesse, Lars und Lammermann, Matthias: *The Efficient Safety Concept of the SpeedE Steer-By-Wire System.* In: Seiten 379–388, 2014.

[GLMH96] Gottschalk, S; Lin, Ming C.; Manocha, Dinesh und Hill, Chapel: *OBB Tree: A Hierarchical Structure for Rapid Interference Detection.* In: *Proceedings of SIGGRAPH 96*, Nr. 8920219, Seiten 171–180, 1996.

[GOC+15] Griggs, Wynita M.; Ordonez-Hurtado, Rodrigo H.; Crisostomi, Emanuele u. a.: *A Large-Scale SUMO-Based Emulation Platform.* In: *IEEE Transactions on Intelligent Transportation Systems*, Band 16, Nr. 6, Seiten 3050–3059, 2015.

[GSB14] Gammell, Jonathan D.; Srinivasa, Siddhartha S. und Barfoot, Timothy D.: *Informed RRT*: Optimal sampling-based path planning focused via direct sampling of an admissible ellipsoidal heuristic.* In: *IEEE International Conference on Intelligent Robots and Systems*, Seiten 2997–3004, 2014.

[Gue15] Guerin, David: *Consideration of wake turbulence during the integration of Remotely Piloted Aircraft into the air traffic management system.* In: *2015 International Conference on Unmanned Aircraft Systems, ICUAS 2015*, Seiten 926–935, 2015.

[Hab17] Habib, Kareem: *Automatic vehicle control systems.* In: *ODI Resume*, Nr. National Highway Traffic Safety Administration, Seite 13, 2017.

[Hay72] Hayward, John C: *Near-Miss Determination Through.* In: *Highway Research Board*, Seiten 24–35, 1972.

[Hil12] Hillenbrand, Martin: *Funktionale Sicherheit nach ISO 26262 in der Konzeptphase der Entwicklung von Elektrik/Elektronik Architekturen von Fahrzeugen*, 2012, Seite 398.

[HKS05] Hillenbrand, Jörg; Kroschel, Kristian und Schmid, Volker: *Situation assessment algorithm for a collision prevention assistant.* In: *IEEE Proceedings. Intelligent Vehicles Symposium, 2005.* Seiten 459–465, IEEE, 2005.

[HSD17] Hoermann, Stefan; Stumper, Daniel und Dietmayer, Klaus: *Probabilistic long-term prediction for autonomous vehicles.* In: *2017 IEEE Intelligent Vehicles Symposium (IV)*, Seiten 237–243, IEEE, 2017.

[HWSK09] Hermes, Christoph; Wohler, C; Schenk, K und Kummert, Franz: *Long-term vehicle motion prediction.* In: *Intelligent Vehicles Symposium, 2009 IEEE*, Seiten 652–657, 2009.

[HWW+11] Hermes, Christoph; Wiest, Jürgen; Wöhler, Christian; Kressel, Ulrich und Kummert, Franz: *Manifold-based Motion Prediction Conclusion.* In: *6. Dortmunder Auto-Tag*, 2011.

[HZG+16] Han, Bing; Zhang, Lixia; Gao, Xinbo; Zhao, Xiaojing und Tao, Dacheng: *Embedded locality discriminant GPLVM for dimensionality reduction*. In: *Proceedings of the International Joint Conference on Neural Networks*, Band 2016-Octob, Seiten 2431–2438, 2016.

[ISO11] ISO: *ISO 26262:2011 , Road vehicles - Functional safety*. Internationale Organisation für Normung, 2011.

[Jol76] Jolly, Alexander C: *Trajectory Generation by Piecewise Spline Interpolation*. In: *Notes*, 1976.

[JSW17] Junietz, P; Schneider, Jan. und Winner, Hermann: *Metrik zur Bewertung der Kritikalität von Verkehrssituationen und -szenarien*. In: *11. Workshop Fahrerassistenzsysteme und automatisiertes Fahren.FAS 2017*, Seiten 149–160, 2017.

[KEBB12] Krajzewicz, Daniel; Erdmann, Jakob; Behrisch, Michael und Bieker, Laura: *Recent Development and Applications of {SUMO - Simulation of Urban MObility}*. In: *International Journal On Advances in Systems and Measurements*, Band 5, Nr. 3, Seiten 128–138, 2012.

[Knu98] Knuth, Donald Ervin: *The art of computer programming, Volume 2, Seminumerical algorithms*. 3rd ed (Online-Ausg.), Addison-Wesley, Upper Saddle River, NJ, 1998, Online–Ressource (1 v.)

[KNW+15] Kunz, Felix; Nuss, Dominik; Wiest, Jurgen u. a.: *Autonomous driving at Ulm University: A modular, robust, and sensor-independent fusion approach*. In: *IEEE Intelligent Vehicles Symposium, Proceedings*, Band 2015-Augus, Nr. Iv, Seiten 666–673, 2015.

[KY00] Kuchar, J K und Yang, L C: *A review of conflict detection and resolution modeling methods*. In: *IEEE Transactions on Intelligent Transportation Systems*, Band 1, Nr. 4, Seiten 179–189, 2000.

[KY97] Kuchar, James K und Yang, Lee C: *Survey of conflict detection and resolution modeling methods*. In: *IEEE Trans. Robot. Autom.*, Band 1, Nr. 4, Seiten 179–189, 1997.

[LAB+11] Levinson, Jesse; Askeland, Jake; Becker, Jan u. a.: *Towards fully autonomous driving: Systems and algorithms*. In: *IEEE Intelligent Vehicles Symposium, Proceedings*, Nr. Iv, Seiten 163–168, 2011.

[LaV06] LaValle, Steven M.: *Planning Algorithms*. In: *Planning Algorithms*, Seiten 1–826, 2006.

[Law04] Lawrence, Neil D.: *Gaussian Process Latent Variable Models for Visualisation of High Dimensional Data*. In: *Proc. {NIPS}*, 2004.

[Law05] Lawrence, Neil: *Probabilistic non-linear Principal Component Analysis with Gaussian Process Latent Variable Models*. In: *Journal ofMachine Learning Research*, Band 6, Seiten 1783–1816, 2005.

[LHC+16] Leu, Kuen Long; Huang, Hsiang; Chen, Yung Yuan; Huang, Li Ren und Ji, Kung Ming: *An intelligent brake-by-wire system design and analysis in accordance with ISO-26262 functional safety standard.* In: *2015 International Conference on Connected Vehicles and Expo, ICCVE 2015 - Proceedings*, Seiten 150–156, 2016.

[LLS+15] Lee, Inho; Lee, Kang Kyu; Sim, Okkee u. a.: *Collision Detection System for thePractical Use of the Humanoid Robot.* In: *2015 IEEE-RAS 15th International Conference on Humanoid Robots (Humanoids)*, Seiten 972–976, 2015.

[LSNM07] Loft, Shayne; Sanderson, Penelope M.; Neal, Andrew und Mooij, Martijn: *Modeling and Predicting Mental Workload in En Route Air Traffic Control : Critical Review and Broader Implications.* In: *Human Factors*, Band 49, Nr. 3, Seiten 376–399, 2007.

[LVL14] Lefèvre, Stéphanie; Vasquez, Dizan und Laugier, Christian: *A survey on motion prediction and risk assessment for intelligent vehicles.* In: *ROBOMECH Journal*, Band 1, Nr. 1, Seite 1, 2014.

[Mai14] Maier, Christoph: *Integriertes Modell zur Entwicklung von funktional sicheren Produkten in der Automobilbranche*, 2014, Seite 149.

[Mar12] Marchanka, Aliaksandr: *Analysis of ISO26262 standard application in development of steer-by-wire systems.* Magisterarb., 2012, Seite 52.

[McK16] McKinsey & Company: *Delivering Change Die Transformation des Nutzfahrzeugsektors bis 2025.* In: Nr. September, Seite 46, 2016.

[Met87] Metropolis, N: *The beginning of the Monte Carlo method.* In: *Los Alamos Science*, Band 15, Seiten 125–130, 1987.

[PFTV07] Press, William; Flannery, Brian; Teukolsky, Saul und Vetterling, William: *Numerical Recipes: The Art of Scientific Computing - Third Edition*, 2007, Seite 1235.

[Ras16] Rastgoufard, Rastin: *GPLVM and Lava Floor Distance for Label-Deficient Semi-Supervised Learning : Case Study.* In: 2016.

[Ros17] Rosenband, Daniel L: *Inside Waymo ' s Self-driving Car : My Favorite Transistors.* In: Band 3, Seiten 20–22, 2017.

[RS41] Riekert, P. und Schunck, T. E.: *Zur Fahrmechanik des gummibereiften Kraftfahrzeugs.* In: *Ingenieur-Archiv*, Band 12, Nr. 1, Seite 70, 1941.

[RVVD14] Reuter, Stephan; Vo, Ba-Tuong; Vo, Ba-Ngu und Dietmayer, Klaus: *Multi-Object Tracking Using Random Finite Sets.* In: *Proc. FUSION-14*, Seite 8, 2014.

[SAE] SAE: *SAE J3016, Taxonomy and Definitions for Terms Related to On-Road Motor Vehicle Automated Driving Systems.* SAE International.

[SD18] Stumper, Daniel und Dietmayer, Klaus: *Towards Criticality Characterization of Situational Space*. In: *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*, Seiten 3378–3382, IEEE, 2018.

[SHB10] Schramm, Dieter; Hiller, Manfred und Bardini, Roberto: *Einspurmodelle*. In: *Modellbildung und Simulation der Dynamik von Kraftfahrzeugen*, Seiten 243–275, Springer Berlin Heidelberg, Berlin, Heidelberg, 2010.

[SHB14] Schramm, Dieter; Hiller, Manfred und Bardini, Roberto: *Vehicle Dynamics*. In: Seiten 223–245, 2014.

[SKPD16] Stumper, Daniel; Knapp, Andreas; Pohl, Martin und Dietmayer, Klaus: *Towards Characterization of Driving Situations via Episode-Generating Polynomials*. In: *Advanced Microsystems for Automotive Applications 2016*, 2016.

[Smi11] Smith, Arthur P.: *Using real-time aircraft reports of wind and environmental parameters to enable dynamic cockpit-based wake tools*. In: *ICNS 2011 - Integrated Communications, Navigation and Surveillance Conference: Renovating the Global Air Transportation System, Proceedings*, Seiten 1–7, 2011.

[SRE+12] Spanfelner, Bernd; Richter, Detlev; Ebel, Susanne u. a.: *Challenges in applying the ISO 26262 for driver assistance systems*. In: *Tagung Fahrerassistenz, München*, Band 15, Nr. 16, Seiten 1–23, 2012.

[SSS17] Shalev-Shwartz, Shai; Shammah, Shaked und Shashua, Amnon: *On a Formal Model of Safe and Scalable Self-driving Cars*. In: Seiten 1–30, 2017.

[TCL14] Tang, Tito; Chucholowski, Frederic und Lienkamp, Markus: *Teleoperiertes Fahren Grundlagen und Systementwurf*. In: *ATZ - Automobiltechnische Zeitschrift*, Band 116, Nr. 2, Seiten 30–33, 2014.

[THH00] Treiber, Martin; Hennecke, Ansgar und Helbing, Dirk: *Congested traffic states in empirical observations and microscopic simulations*. In: *Physical review E*, Band 62, Nr. 2, Seite 1805, 2000.

[TMD+06] Thrun, Sebastian; Montemerlo, Mike; Dahlkamp, Hendrik u. a.: *Stanley: The robot that won the DARPA Grand Challenge*. In: *Journal of Field Robotics*, Band 23, Nr. 9, Seiten 661–692, 2006.

[TSP+18] Tas, Omer Sahin; Salscheider, Niels Ole; Poggenhans, Fabian u. a.: *Making Bertha Cooperate-Team AnnieWAY's Entry to the 2016 Grand Cooperative Driving Challenge*. In: *IEEE Transactions on Intelligent Transportation Systems*, Band 19, Nr. 4, Seiten 1262–1276, 2018.

[UMR+15a] Ulbrich, Simon; Menzel, Till; Reschka, Andreas; Schuldt, Fabian und Maurer, Markus: *Defining and Substantiating the Terms Scene, Situation, and Scenario for Automated Driving*. In: *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC*, Band 2015-Octob, Seiten 982–988, 2015.

[UMR+15b] Ulbrich, Simon; Menzel, Till; Reschka, Andreas; Schuldt, Fabian und Maurer, Markus: *Defining and Substantiating the Terms Scene, Situation, and Scenario for Automated Driving*. In: *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC*, Band 2015-Octob, Seiten 982–988, 2015.

[Unt13] Unterreiner, Michael: *Modellbildung und Simulation von Fahrzeugmodellen unterschiedlicher Komplexität*. In: 2013.

[Wei13] Weitzel, Dirk Alexander: *Objektive Bewertung der Kontrollierbarkeit nicht situationsgerechter Reaktionen umfeldsensorbasierter Fahrerassistenzsysteme*. Dissertation, 2013, Seite 145.

[WJWW16] Wachenfeld, Walther; Junietz, Philipp; Wenzel, Raphael und Winner, Hermann: *The worst-time-to-collision metric for situation identification*. In: *IEEE Intelligent Vehicles Symposium, Proceedings*, Band 2016-Augus, Nr. Iv, Seiten 729–734, 2016.

[WW15] Wachenfeld, Walther und Winner, Hermann: *Die Freigabe des autonomen Fahrens*. In: *Autonomes Fahren*. Kap. 21, Seiten 440–464, 2015.

[WZKT10] Werling, M; Ziegler, J; Kammel, S und Thrun, S: *Optimal trajectory generation for dynamic street scenarios in a Frenét Frame*. In: *Robotics and Automation (ICRA), 2010 IEEE International Conference on*, Seiten 987–993, 2010.

[ZBDS14] Ziegler, Julius; Bender, Philipp; Dang, Thao und Stiller, Christoph: *Trajectory planning for Bertha - A local, continuous method*. In: *IEEE Intelligent Vehicles Symposium, Proceedings*, Nr. Iv, Seiten 450–457, 2014.

[ZBS+14] Ziegler, Julius; Bender, Philipp; Schreiber, Markus u. a.: *Making bertha drive-an autonomous journey on a historic route*. In: *IEEE Intelligent Transportation Systems Magazine*, Band 6, Nr. 2, Seiten 8–20, 2014.

[ZS10] Ziegler, Julius und Stiller, Christoph: *Fast collision checking for intelligent vehicle motion planning*. In: *IEEE Intelligent Vehicles Symposium, Proceedings*, Seiten 518–522, 2010.

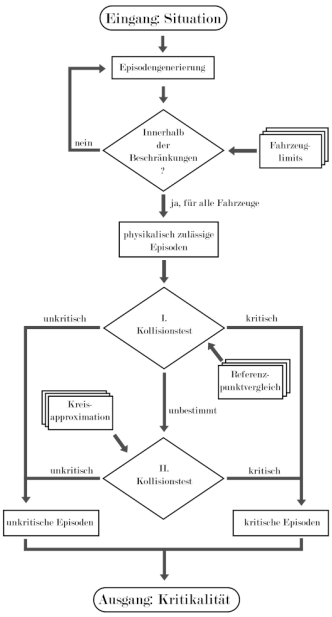

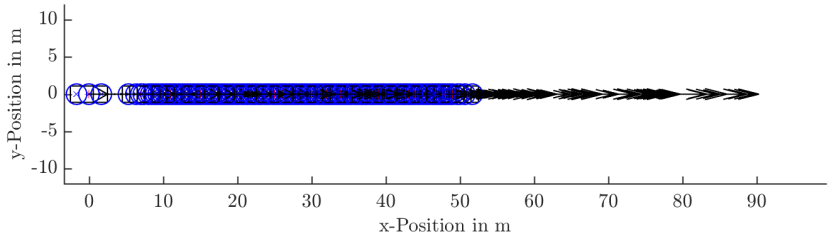

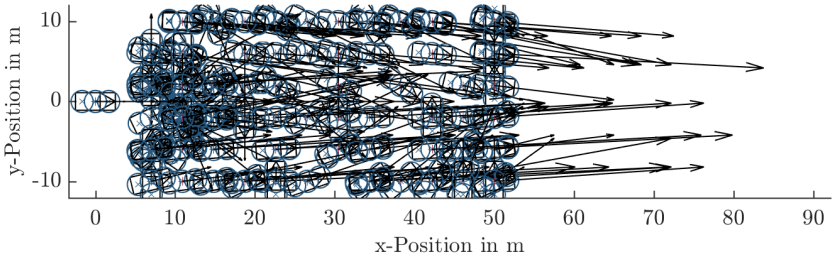

ISBN 978-3-941543-52-2 (E-Book)