

Abschlussbericht zum Projekt

Hybride Statistische Lernmethoden für die Embedded-Umsetzung von Sicherheitsfunktionen im Fahrzeug [HySLEUS]

der Technischen Hochschule Ingolstadt

- Zuwendungsempfänger:** Technische Hochschule Ingolstadt
Zentrum für Angewandte Forschung (ZAF)
Esplanade 10
85049 Ingolstadt
- Projektpartner:** Automotive Safety Technologies GmbH, Ingolstadt
- Förderkennzeichen:** 03FH034PX4
- Projektleitung:** Prof. Dr.-Ing. Michael Botsch
 0841/9348-2721
 michael.botsch@thi.de
- Projektlaufzeit:** 17.11.2014 –31.01.2018

Inhalt

I.	Kurzdarstellung	4
1.	<i>Aufgabenstellung</i>	4
2.	<i>Voraussetzungen/Ausgangslage</i>	4
2.1.	Voraussetzungen, unter denen das Projekt durchgeführt wurde	4
2.2.	Wissenschaftlicher und technischer Stand, an den angeknüpft wurde.....	5
3.	<i>Planung und Ablauf des Vorhabens</i>	6
4.	<i>Anknüpfungspunkte in Wissenschaft und Technik</i>	8
5.	<i>Zusammenarbeit mit anderen Stellen</i>	9
II.	Eingehende Darstellung	9
1.	<i>Soll-Ist-Vergleich der geplanten und erzielten Ergebnisse sowie der eingesetzten Mittel</i>	9
AP1:	Dynamische Modelle und Verletzungsschwere	10
AP2:	Hybrides Verfahren für die Trajektorienplanung in der Fahrzeugsicherheit	15
AP3:	Embedded Umsetzung.....	17
AP4:	Darstellung im Fahrzeug und Validierung	19
2.	<i>Erläuterung der wichtigsten Positionen im zahlenmäßigen Nachweis</i>	21
3.	<i>Notwendigkeit und Angemessenheit der geleisteten Arbeit</i>	21
4.	<i>Voraussichtlicher Nutzen und Verwertbarkeit des Ergebnisses</i> <i>(Fortschreibung des Verwertungsplanes)</i>	23
5.	<i>Fortschritte auf dem Gebiet des Vorhabens bei anderen Stellen während der</i> <i>Durchführung</i>	24
6.	<i>Geplante und erfolgte Veröffentlichungen im Rahmen des Vorhabens</i>	25
III.	Erfolgskontrollbericht	26
IV.	Kurzfassung/Berichtsblatt	26

B. Abbildungen

Abbildung 1: Arbeitsplan.....	7
Abbildung 2: Zweispurmodell und Geometrisches Modell	10
Abbildung 3: Simulationsergebnis Lenkwinkelsprung-Manöver	11
Abbildung 4: Simulationsergebnis Doppelspurwechsel-Manöver	12
Abbildung 5: Szenario 1 [29]	13
Abbildung 6: Szenario 2 [29]	13
Abbildung 7: Simulierte kurvige Straße [14].....	14
Abbildung 8: Simuliertes Kreuzungsszenario [14].....	14
Abbildung 9: Architektur zum Testen von Algorithmen mit Fahrzeug	19
Abbildung 10: Fahrzeug mit montiertem Fahrroboter	20
Abbildung 11: Kritische Verkehrssituation mittels Attrappen auf dem CARISSMA-Freiversuchsgelände.	20
Abbildung 12: Ausgaben	21

C. Tabellen

Tabelle 1: Vergleich zwischen Augmented CL-RRT und Hybrid Augmented CL-RRT Algorithmus.....	16
Tabelle 2: Vergleich zwischen Augmented CL-RRT und Augmented CL-RRT+ Algorithmus	17
Tabelle 3: Vergleich zwischen Augmented CL-RRT+ und Hybrid Augmented CL-RRT+ Algorithmus	17
Tabelle 4: Benötigte Rechenressourcen für Trajektorienplanungsalgorithmen	18
Tabelle 5: Ausgaben.....	21

I. Kurzdarstellung

1. Aufgabenstellung

Die zunehmende Mobilität im Straßenverkehr stellt die bestehende Infrastruktur aber auch die Hersteller von Fahrzeugen vor große Herausforderungen. Es gilt eine immer größer werdende Anzahl an Personen und Gütern schnell und komfortabel zu transportieren und zugleich deren Sicherheit im Verkehr zu gewährleisten. Durch den Einzug von vorausschauenden Sensoren wie z. B. Radar oder Kamera in die Fahrzeuge eröffnen sich neue Möglichkeiten, den Verkehrsfluss effizienter und sicherer zu machen. Erste Beispiele für eine verbesserte Mobilität, die erst durch solche Sensoren realisierbar wurden, sind das Adaptive Cruise Control (ACC), der Spurhalteassistent oder die automatische Notbremsung (Autonomous Emergency Braking). Diese Fahrzeugfunktionen stellen nur einen ersten Schritt auf dem Weg zu einer individuell anpassbaren Automatisierungsstufe des Fahrens und zur „Vision Zero“, der Vision von Null Verkehrstoten, dar. Ein zentrales Element zur Erreichung dieser Ziele ist die Trajektorienplanung zur Vermeidung von Kollisionen in kritischen Verkehrssituationen, wobei die physikalischen Grenzen der Fahrzeugbewegung eingehalten werden. Falls eine Kollision doch unvermeidbar wird, kann noch vor dem Aufprall durch die Beeinflussung der Trajektorie diejenige Fahrzeugbewegung angesteuert werden, bei der die geschätzte Verletzungsschwere am geringsten ist. Die Berechnung solcher genauen Trajektorien für den Einsatz in Fahrzeugen setzt voraus, dass

- die Fahrdynamik der Verkehrsteilnehmer präzise modelliert werden kann,
- mögliche Kollisionen gut vorhergesagt werden können,
- geeignete Schätzverfahren für die Verletzungsschwere vorhanden sind,
- die Umsetzung der Algorithmen so ressourcensparend ist, dass die Trajektorienplanung auf Automotive-Mikrocontroller in Echtzeit realisiert werden kann.

Im Projekt HySLEUS wurden neue Methoden für den Einsatz hybrider statistischer Lernmethoden in der Fahrzeugsicherheit erforscht und anschließend implementiert, die es ermöglichen, die oben genannten Anforderungen an eine genaue Trajektorienplanung für Fahrzeugsicherheitssysteme zu erfüllen. Die Kombination von datenbasierten Lernalgorithmen und physikalischen Modellen spielt eine besondere Rolle, so dass die resultierenden Systemmodule in sicherheitskritischen Anwendungen eingesetzt werden können. Die hybriden statistischen Lernmethoden bieten das Potenzial, komplexe Trajektorienplanungen mit hoher Güte und geringen Rechenressourcen umzusetzen, so dass sie in Fahrzeuge integriert werden können und damit einen Beitrag zur sicheren Mobilität leisten.

2. Voraussetzungen/Ausgangslage

2.1. Voraussetzungen, unter denen das Projekt durchgeführt wurde

Das Projekt HySLEUS wurde von der Technischen Hochschule Ingolstadt (THI) mit Beteiligung des Wissenschafts-Praxis-Kooperation-Partners (WPK), Automotive Safety

Technologies GmbH (ASTech), durchgeführt. Aus Eigenmitteln konnte die THI das Projekt HySLEUS, aufgrund seiner Komplexität sowie seines inhaltlichen und finanziellen Umfangs, nicht stemmen. Aus diesem Grund wurden an der THI eine volle Stelle für die gesamte Laufzeit (36 Monate) und eine halbe Stelle für die halbe Laufzeit (18 Monate) des Projekts aus Mitteln des BMBF und des WPK-Partners ASTech geschaffen. Von November 2017 bis Januar 2018 wurde die halbe Stelle auf eine Vollzeitstelle erweitert, da die Bearbeitung der geplanten Aufgaben aufgrund ihrer Komplexität mehr Zeit in Anspruch genommen hat. Dies war in der Phase des Projektantrags nicht absehbar. Die im Projekt noch vorhandenen Mittel wurden zum Ausbau dieser Position verwendet, es waren keine zusätzlichen Mittel erforderlich.

Der größte Anteil der Mittel für das HySLEUS-Projekt wurde vom BMBF über das Förderprogramm „Forschung an Fachhochschulen mit Unternehmen“ (FHprofUnt) bereitgestellt. Der WPK-Partner ASTech GmbH hat sich auch finanziell an HySLEUS beteiligt. Zusätzlich hat der WPK-Partner das Projekt durch das Ausleihen teurer Messtechnik sowie durch die Unterstützung bei der Inbetriebnahme eines Mikrocontrollers (μC) und seiner Anbindung an ein Versuchsfahrzeug gefördert.

Aus den bewilligten Projektmitteln wurden zusätzlich zu den Personalkosten auch die für die Durchführung der Forschungsarbeiten notwendige technische Ausstattung und Dienstreisen zu Konferenzen finanziert. Die notwendige technische Ausstattung bestand aus einer Workstation zur Generierung einer Szenariendatenbank und zwei Starter-Kits für Automotive- μC .

2.2. Wissenschaftlicher und technischer Stand, an den angeknüpft wurde

Die wissenschaftlichen Methoden zur Durchführung der Trajektorienplanung für Fahrzeuge lassen sich in folgende Kategorien einteilen: Potentialfeldverfahren [1], gitterbasierte Verfahren [2], „Sampling“-basierte Verfahren [3] und diskrete Optimierungsverfahren [4]. Während Potentialfeldverfahren trotz stark vereinfachter Modellierung der Fahrdynamik mögliche Trajektorien nicht immer finden, muss bei „Sampling“-basierten Verfahren auf Heuristiken zurückgegriffen werden. In gitterbasierten Verfahren wird die Fahrzeugumgebung in Gitter quantisiert. Für praktische Anwendungen, in denen die Fahrdynamik realitätsnah modelliert werden soll, ist eine feingranulare Quantisierung des Gitters notwendig. Die angewandten Suchalgorithmen benötigen dabei Speicherressourcen, die mit dem Quantisierungsgrad exponentiell steigen. Diskrete Optimierungsverfahren lösen für einige Trajektorien den Satz an Differentialgleichungen, die der Fahrdynamik zugrunde liegen, numerisch und aus dieser Menge an Trajektorien wird diejenige ausgewählt, die eine vorgegebene Kostenfunktion minimiert. Der Nachteil des Verfahrens ist der hohe Ressourcenverbrauch (Speicher, Laufzeit) für das Finden einer geeigneten Trajektorie und die notwendige Heuristik bei der Wahl der ursprünglichen Kandidatenmenge für die Trajektorien.

Der im Projekt HySLEUS behandelte methodische Ansatz hat statistische Lernverfahren mit genauen Trajektorienberechnungen kombiniert, wobei nur für eine finale Trajektorie Differentialgleichungen, die die Fahrdynamik beschreiben, numerisch berechnet werden. In der Fahrzeugtechnik wurden in den letzten Jahrzehnten zahlreiche mathematische Modelle zur Beschreibung der Fahrdynamik von Fahrzeugen entwickelt [5]. Die Modelle

unterscheiden sich durch ihre Komplexität und die Genauigkeit mit der sie das Fahrverhalten beschreiben. Während einfache lineare Einspurmodelle die Fahrzeugbewegung für geringe und mittlere Dynamikwerte unter Normalbedingungen realitätsnah darstellen, benötigt man für höhere Dynamikwerte und für die Berücksichtigung der physikalischen Grenzen der Reifenkräfte während eines Fahrmanövers komplexere nichtlineare Zweispurmodelle [6]. Für die Prädiktion eines komfortablen Fahrmanövers ist es ausreichend, vereinfachte Einspurmodelle, wie z. B. „Constant Velocity“, „Constant Acceleration“ oder „Constant Turn Rate“ zu verwenden [7]. Auch die Trajektorienplanung der Teilnehmer an dem DARPA-Wettbewerb „Urban Challenge“ für autonomes Fahren musste auf vereinfachte Modelle zurückgreifen und die Berechnungen zur Trajektorienplanung mittels diskreter Optimierungsverfahren auf leistungsfähigen „Car-PCs“ durchführen [8].

Die Verwendung von Maschinenlernverfahren für Teilaufgaben einer Trajektorienplanung für Fahrzeuge wird in [9] erwähnt, allerdings handelt es sich dabei nicht um sicherheitsrelevante Module. Die dort beschriebene Trajektorienberechnung ist auf ein stationäres Umfeld und niedrige Fahrdynamikwerte eingeschränkt. Die Trajektorienplanung wird dabei auch auf leistungsfähigen „Car-PCs“ durchgeführt.

Das Schätzen der Verletzungsschwere vor einer Kollision, beruhend auf den Informationen vorausschauender Sensoren, ist ein neues Forschungsgebiet. Während die Potentiale von vorausschauenden Sensoren für die Schätzung der Verletzungsschwere in verschiedenen Arbeiten aufgezeigt wurden, die zum Großteil in [10] zusammengefasst sind, fehlt es noch an geeigneten Schätzverfahren um die Verletzungsschwere vor der Kollision zu prognostizieren. Aus diesem Grund sind auch noch keine Fahrzeugsicherheitssysteme verfügbar, die eine prognostizierte Verletzungsschwere für Eingriffe in die Fahrdynamik nutzen.

Heutige aktive Sicherheitssysteme im Fahrzeug die kurz vor einer potentiellen Kollision aktiviert werden, sogenannte Pre-Crash Systeme, beschränken sich bezüglich des automatischen Eingriffs in die Fahrdynamik auf die Notbremsung [11]. Dies ist zum Großteil durch die Komplexität einer Trajektorienplanung für Querdynamikeingriffe in kritischen Fahrsituationen zu erklären. Ein zweiter wichtiger Grund ist die Notwendigkeit, die Trajektorienplanung auf einem Automotive- μ C in Echtzeit durchzuführen. Bei den oben beschriebenen Verfahren mussten trotz vereinfachter Fahrdynamikmodelle die Berechnungen auf einem „Car-PC“ vorgenommen werden.

3. Planung und Ablauf des Vorhabens

Das Projekt wurde in vier Arbeitspakete gegliedert. Eine Übersicht zu den vier Arbeitspaketen AP 1, AP 2, AP 3 und AP 4 ist in Abbildung 1 dargestellt. Zunächst wurden alle notwendigen Schritte für die algorithmische Realisierung der Trajektorienplanung mit hybriden statistischen Lernmethoden durchgeführt. Anschließend wurden die Algorithmen in Automotive- μ C implementiert und die Trajektorienplanung in einem realen Fahrzeug getestet und ausgewertet.

In einigen Unterpaketen mussten kleinere Änderungen vorgenommen werden. Diese Änderungen wurden bereits in den jährlichen Zwischenberichten vorgestellt und werden

auch im Abschnitt II.1 präsentiert. Für die Erreichung der wesentlichen Ziele des Vorhabens innerhalb der Projektlaufzeit hatten diese Anpassungen jedoch keine negativen Auswirkungen.

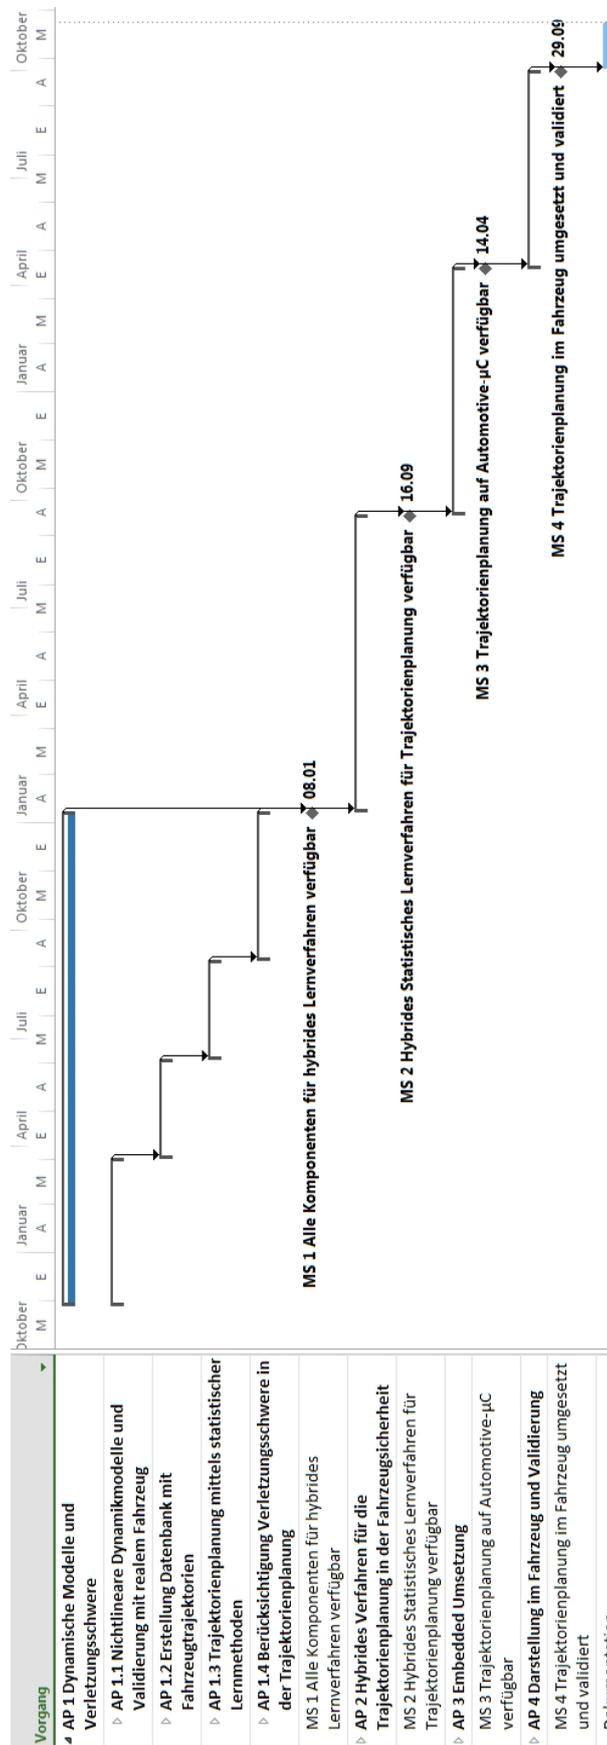


Abbildung 1: Arbeitsplan

4. Anknüpfungspunkte in Wissenschaft und Technik

Trajektorienplanung ist in der Robotik-Community ein bereits weit erforschtes Gebiet. Es gibt in der Literatur Trajektorienplanungsalgorithmen für die Roboterbewegungsplanung [12] im Allgemeinen sowie speziell für die Fahrzeugbewegungsplanung. Diese Algorithmen wurden vor allem im Darpa Urban Challenge 2007 [8] verwendet. Einer dieser Algorithmen, genannt „Closed-Loop Rapidly-exploring Random Trees“ (CL-RRT) [13], war sehr interessant im Zusammenhang mit dem HySLEUS-Projekt, da er das dynamische Fahrzeugmodell im geschlossenen Regelkreis verwendete, um fahrbare sichere Trajektorien zu finden. Mit Methoden und Algorithmen aus dem Bereich des maschinellen Lernens wurde dieser Algorithmus in zwei Varianten erweitert, nämlich Augmented CL-RRT [14] und Augmented CL-RRT+ [15]. Für die Literatur des zweispurigen Fahrzeugdynamikmodells, das in diesem Algorithmus zur Modellierung der Fahrzeugbewegung verwendet wird, sei auf [5] und [16] verwiesen.

In HySLEUS wurden maschinelle Lernalgorithmen verwendet, um die Konvergenz von „Sampling-basierten“ Trajektoriensuchalgorithmen zu beschleunigen. Diese Idee führte zu den beiden eigenentwickelten Algorithmen Augmented CL-RRT und Augmented CL-RRT+. Es gibt auch andere Ansätze, die das „Biased-Sampling“ mit dem RRT-Algorithmus nutzen, um eine schnellere Konvergenz zu erreichen. Einige Beispiele für solche Ansätze sind [17], [18]. Diese Algorithmen verwenden jedoch nur regelbasierte Heuristiken.

Die für den maschinellen Lernalgorithmus verwendeten Eingangsmerkmale sind sogenannte prädizierte Belegungskarten. Da eine Sequenz solcher prädizierter Belegungskarten genutzt wurde, bestand die Aufgabe darin, räumlich-zeitliche Merkmale zu erlernen. Für das maschinelle Lernen von Videosequenzen existieren Ansätze für das Lernen von räumlich-zeitlichen Merkmalen [17], [18]. Diese Ansätze verwenden neuronale Netze („3D-Convolutional Neural Network“). Deswegen wurde auch im HySLEUS-Projekt diese Architektur für neuronale Netze als maschineller Lernalgorithmus verwendet.

Die in HySLEUS entwickelten modellbasierten Trajektorienplanungsalgorithmen, Augmented CL-RRT und Augmented CL-RRT+, können auch Trajektorien mit geringer Verletzungsschwere finden. Diese Trajektorien sind für die Minderung der Folgen einer Kollision nützlich, falls ein Unfall unvermeidbar wird. Die Schwere der Verletzung einer Kollision wurde aus [19] übernommen und anhand von zwei Kriterien definiert: Relativgeschwindigkeit und Art der Kollision (seitlich, vorne oder hinten). Der modulare Aufbau des Algorithmus ermöglicht allerdings auch die Betrachtung von komplexeren Modellen der Verletzungsschwere wie z. B. die Modelle in [20].

Die Algorithmen wurden in Matlab entwickelt. Verschiedene Matlab-Toolboxen wurden in verschiedenen Projektphasen eingesetzt. „Matlab Coder“ und „Simulink Coder“ wurden verwendet, um automatisch Code auf verschiedenen Hardware-Plattformen zu generieren, zu optimieren und zu implementieren. Die Compiler für jede Hardwareplattform hatten eine Schnittstelle für Matlab und Simulink Coder.

Die im Projekt entwickelten und implementierten Methoden der Kombination von maschinellen Lernalgorithmen und modellbasierten Algorithmen wurden auf internationalen Konferenzen vorgestellt und mit anderen Wissenschaftlern diskutiert. Dadurch kam es zu einem regen fachlichen Austausch mit der Arbeitsgruppe von Prof. Utschick an der TU München und zur Teilnahme an der BMW Summer School 2017.

5. Zusammenarbeit mit anderen Stellen

Das Forschungsprojekt HySLEUS erforderte eine enge Einbindung der Kooperationspartner in alle Arbeitspakete. Die THI übernahm den Teil der wissenschaftlichen Grundlagenarbeit, die Umsetzung der entwickelten Ansätze in der Simulation und mit dem Testfahrzeug auf der Teststrecke. Die ASTech GmbH begleitete die TH Ingolstadt in allen Phasen des Projektes. Dies umfasste die Bereitstellung von Fahrzeugmanöverdaten, die Unterstützung bei der Optimierung und Implementierung der Algorithmen auf den Embedded Plattformen und die Unterstützung bei der Validierung der Algorithmen im Testfahrzeug. Außerdem wurden die entwickelten Ansätze durch regelmäßige Treffen und Telefonate gemeinsam diskutiert und bewertet. Der WPK-Partner ASTech beabsichtigt die entwickelte Methodik für den Entwurf von Trajektorienplanungsalgorithmen in verschiedenen zukünftigen Produkten direkt oder für Referenzalgorithmen zu verwenden.

Die TU München und die TH Ingolstadt haben Ende 2015 einen Promotionsverbund beschlossen. Wissenschaftliche Mitarbeiter der TH Ingolstadt können im Verbundkolleg „Mobilität und Verkehr“ an der TU München promovieren [21]. Der seit November 2014 im Projekt beschäftigte wissenschaftliche Mitarbeiter ist einer der ersten Doktoranden in diesem Verbundkolleg. Seit November 2016 ist er an der TUM Graduate School eingeschrieben und sein Doktorvater an der TU München ist Professor Wolfgang Utschick vom Institut „Methoden der Signalverarbeitung“. In regelmäßigen Gesprächen mit Prof. Utschick wurden die in HySLEUS entwickelten wissenschaftlichen Methoden ausführlich diskutiert.

II. Eingehende Darstellung

1. Soll-Ist-Vergleich der geplanten und erzielten Ergebnisse sowie der eingesetzten Mittel

Der wesentliche Teil der Zuwendung wurde für Personalausgaben (Wissenschaftlicher Mitarbeitern, Studentische Hilfskräfte) verwendet. Die entstandenen Reisekosten resultieren aus der Teilnahme an wissenschaftlichen Fachtagungen, welche als Plattformen für die Präsentation von Forschungsergebnissen genutzt wurden. Darüber hinaus wurde ein Teil der Zuwendung für den Einkauf einer Workstation zur Generierung von Daten für die Entwicklung hybrider statistischer Lernmethoden und zweier Starter-Kits (Texas Instrument TMS570 und Raspberry-Pi) zur eingebetteten Implementierung der entwickelten Algorithmen genutzt.

Die nachfolgenden Abschnitte beinhalten die Darstellung der Ergebnisse der einzelnen Arbeitspakete (AP 1 - AP 4). Für jedes dieser Arbeitspakete erfolgt zunächst eine Darstellung der gesetzten Ziele und anschließend werden jeder Aufgabenstellung die erzielten Ergebnisse gegenübergestellt.

AP1: Dynamische Modelle und Verletzungsschwere

Ziele:

Ziel des AP 1 war es, alle Komponenten, die zur Umsetzung der Trajektorienplanung mittels hybriden statistischen Lernverfahren notwendig sind, fertigzustellen.

Aufgabenstellung:

Das erste Arbeitspaket (AP 1) ist in vier Unter-Arbeitspakete unterteilt. Im ersten Unter-Arbeitspaket AP 1.1 sollten verschiedene Dynamikmodelle für kritische Fahrmanöver analysiert werden. Anschließend sollte ein geeignetes Dynamikmodell für den Einsatz auf einem „Car-PC“ implementiert werden. Das Modell sollte mit Hilfe eines realen Fahrzeugs in Zusammenarbeit mit dem WPK-Partner ASTech in AP 1.1.2 validiert werden. Im zweiten Unter-Arbeitspaket AP 1.2 sollte simulativ, beruhend auf dem validierten Fahr-dynamikmodell, eine große Menge an repräsentativen Daten generiert werden. Diese Daten stellen die Grundlage für die Verwendung der statistischen Lernverfahren dar, die in AP 1.3 für die Trajektorienplanung genutzt wurden. Die Berücksichtigung anderer Verkehrsteilnehmer und die Schätzung einer Verletzungsschwere als Bestandteil der Trajektorienplanungsaufgabe wurden in AP 1.4 behandelt.

Ergebnisse:

1) Nichtlineare Dynamikmodelle und Validierung mit realem Fahrzeug

Zunächst wurde eine Literaturrecherche zu Bewegungsmodellen von Verkehrsteilnehmern durchgeführt. Zu den wichtigsten Publikationen gehören [22], [16], [23], [24] und [25].

Zwei Dynamikmodelle für Fahrzeuge in kritischen Fahrmanövern wurden in Matlab implementiert. Die Umsetzung in Matlab erlaubt den Vergleich der jeweiligen Modelle. Eine graphische Darstellung der Modelle ist in Abbildung 2 zu finden. Die betrachteten und implementierten Dynamikmodelle sind: das Zweispurmodell und das geometrische Modell.

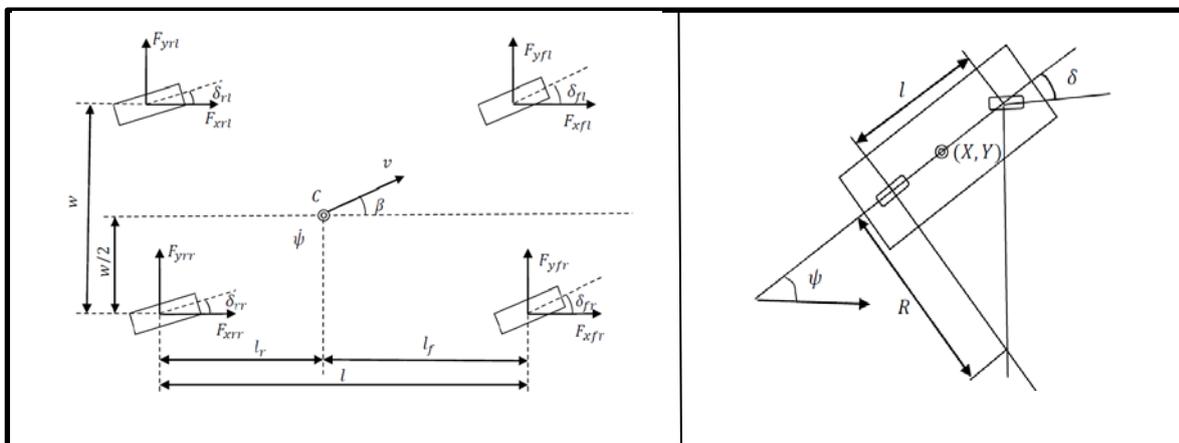


Abbildung 2: Zweispurmodell und Geometrisches Modell

Die Validierung der dynamischen Modelle mit realen Daten wurde realisiert. Der WPK-Partner ASTech GmbH hat dafür Daten von Fahrmanövern, die im Vorfeld abgesprochen wurden, mit einem Fahrzeug, Audi A6 Avant (2013), auf einem Testgelände gemessen und zur Verfügung gestellt. Das Fahrzeug wurde mit externen GPS-Sensoren ausgestattet, um die Position des Fahrzeugs während des gesamten Manövers zu messen. Zusätzlich gab es einen Zugang zum Fahrzeug-CAN-Bus und damit die Möglichkeit Daten, wie z.B. Geschwindigkeit, Beschleunigung, Lenkwinkel, von fahrzeuginternen Sensoren zu erfassen. ASTech stellte außerdem alle technischen Daten des Audi A6 Avant zur Verfügung. Die Nichtlinearität des Reifen-Straßen-Kontakts wurde basierend auf der „Magic Tire Formula“ [5] modelliert und in einem Zweispurmodell implementiert. Die für die „Magic Tire Formula“ sowie auch andere im Zweispurmodell benötigten Parameter, wie z. B. der Reibungskoeffizient, wurden mit Hilfe der Messdaten geschätzt und anschließend gegen andere Messdaten validiert. Zur Validierung von dynamischen Modellen wurden zwei Manöver analysiert: Lenkwinkelsprung und Doppelspurwechsel.

- Lenkwinkelsprung: Während einer Fahrt mit konstanter Geschwindigkeit wird der Lenkwinkel sprunghaft auf einen konstanten Wert geregelt.
- Doppelspurwechsel: Das Fahrzeug fährt mit einer konstanten Geschwindigkeit einen doppelten Spurwechsel.

ASTech stellte ausreichend Daten für diese zwei Manöver zur Verfügung. Die unbekannt Parameter wurden mit Hilfe der Daten eines Lenkwinkelsprung-Manövers geschätzt und anschließend gegen alle verfügbaren Daten validiert. Als Eingangsdaten für das geometrische Modell und das Zweispurmodell wurde die Startposition (X- und Y-Koordinaten) des Fahrzeugs sowie Geschwindigkeit und Lenkwinkel über einen Zeitraum verwendet. Als Ausgangsdaten der Simulation erhielt man die Fahrzeugposition über den gleichen Zeitraum. Die Fahrzeugposition aus der Simulation wurde mit der, mittels GPS-Sensoren gemessenen, Referenz-Fahrzeugposition verglichen. Beispiele für Simulationsergebnisse werden in Abbildung 3 und Abbildung 4 gezeigt. Zusätzlich zu dem Zweispurmodell wurde das geometrische Modell mit den vorliegenden Daten analysiert. Die Untersuchungen haben gezeigt, dass wie erwartet, das Zweispurmodell genauer ist als das geometrische Modell. Deshalb wurde beschlossen das Zweispurmodell für die Trajektorienplanung zu verwenden.

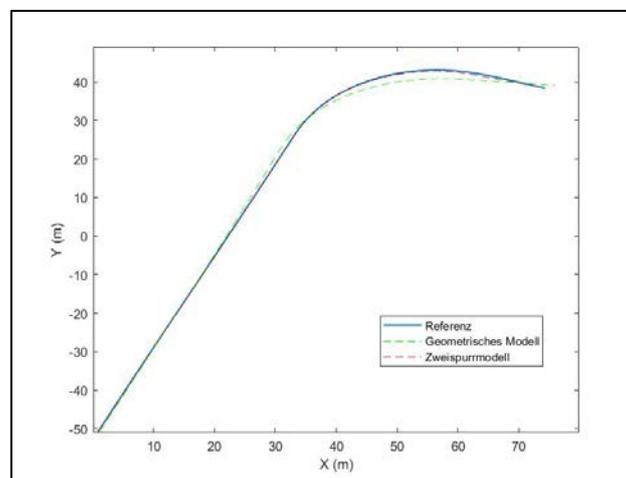


Abbildung 3: Simulationsergebnis Lenkwinkelsprung-Manöver

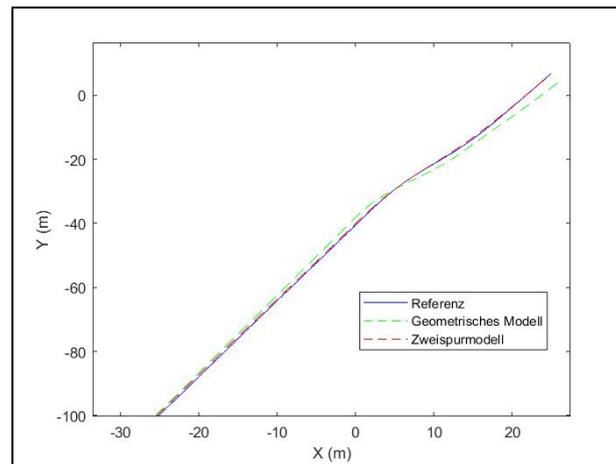


Abbildung 4: Simulationsergebnis Doppelspurwechsel-Manöver

2) Modellbasierter Trajektorienplanungsalgorithmus

Ein Trajektorienplanungsalgorithmus für das Finden von Ausweichtrajektorien kurz vor einer Kollision wurde entworfen und umgesetzt. Zunächst wurden verschiedene Trajektorienplanungsalgorithmen bzgl. ihrer Eignung zum Finden von Kollisionsvermeidungstrajektorien in einem dynamischen Umfeld mit vielen Objekten untersucht: gitterbasierte Algorithmen wie A* [26], D* [27], Potenzialfeldmethoden [1] aber auch Sampling-Algorithmen wie „Rapidly-exploring Random Tree“ (RRT) [28]. Aufgrund seiner schnellen Konvergenz und der Fähigkeit, eine Trajektorie unter Berücksichtigung der nichtholonomen Zwangsbedingungen bei der Beschreibung der Fahrdynamik eines Fahrzeugs zu bestimmen, wurde der Sampling-Algorithmus RRT als Grundlage für weitere Betrachtungen ausgewählt. Es wurde bereits weltweit an verschiedenen Forschungseinrichtungen im Bereich der mobilen Robotik an Erweiterungen des RRT Algorithmus geforscht. Die daraus hervorgegangenen Publikationen und gewonnenen Ergebnisse wurden analysiert, um beurteilen zu können, ob existierende Varianten des RRT-Algorithmus für die Planung von Kollisionsvermeidungstrajektorien im Straßenverkehr verwendet werden können. Obwohl der RRT-Algorithmus auch für die Simulation von Verkehrsszenarien eingesetzt wurde, gab es keine Variante, bei der die prädictierten Aufenthaltsorte aller Verkehrsteilnehmer für den gesamten Prädiktionszeitraum berücksichtigt werden. Deshalb wurde eine neue Variante des RRT-Algorithmus, Augmented CL-RRT [29], gemäß den Anforderungen im Projekt, d. h. Kollisionsvermeidungstrajektorien unter Berücksichtigung der dynamischen Einschränkungen und der prädictierten Aufenthaltsorte aller Verkehrsteilnehmer in dynamischen Multi-Objekt-Szenarien zu finden, entwickelt. Der Algorithmus verwendet Vorhersagen für alle Verkehrsteilnehmer und nutzt bei der Suche nach kollisionsfreien Trajektorien mehrere vordefinierte Beschleunigungsprofile, um zusätzlich zur Querdynamik auch Unterschiede in der Längsdynamik zu ermöglichen. Anschließend nutzt der Algorithmus als Maß zur Bewertung der gefundenen Vermeidungstrajektorien den maximalen Lenkwinkel in dem jeweiligen Manöver und wählt die „komfortabelste“ Trajektorie bzgl. der Querdynamik aus.

Exemplarisch zeigen die Abbildung 5 und Abbildung 6 zwei ähnliche Verkehrsszenarien zu einem Zeitpunkt t_0 , wenn eine Kollision für das EGO-Fahrzeug mit Fahrzeug 1 vorhergesagt wird. Das Fahrzeug 1 hat dabei wegen eines Fußgängers stark gebremst. Die

Bewegungsrichtung aller Fahrzeuge und Fußgänger wird durch Pfeile dargestellt und alle Fahrzeuge, mit Ausnahme des EGO-Fahrzeugs, sind nummeriert. Das EGO-Fahrzeug, Fahrzeug 2 und Fahrzeug 3 fahren mit gleicher Geschwindigkeit von 50 km/h. Der einzige Unterschied zwischen beiden Szenarien ist die Ausgangsposition des Fahrzeuges 3. Der Augmented CL-RRT Algorithmus untersucht hier sichere Kollisionsvermeidungstrajektorien für eine starke Bremsung (-8 m/s^2), eine positive Beschleunigung (4 m/s^2) und ein konstantes Geschwindigkeitsprofil. Die „komfortabelste“ Trajektorie bezüglich der Querdynamik wird anschließend ausgewählt. Der finale Zustand der besten Trajektorie ist in den Abbildungen durch dickere Linien des EGO-Fahrzeugs hervorgehoben.

Es gibt einige Nachteile des Augmented CL-RRT Algorithmus. Erstens verwendet er nur vordefinierte Beschleunigungsprofile. Das heißt, dass die Fahrmöglichkeiten bzgl. der Längsdynamik eingeschränkt sind. Daher stößt dieser Algorithmus in Verkehrsszenarien mit vielen dynamischen und statischen Objekten an seine Grenzen. Daher wurde dieser Algorithmus erweitert, um zufällige aber physikalisch mögliche Längsbeschleunigungsprofile zu ermöglichen. Dieser erweiterte Algorithmus wurde „Augmented CL-RRT+“ [15] benannt.

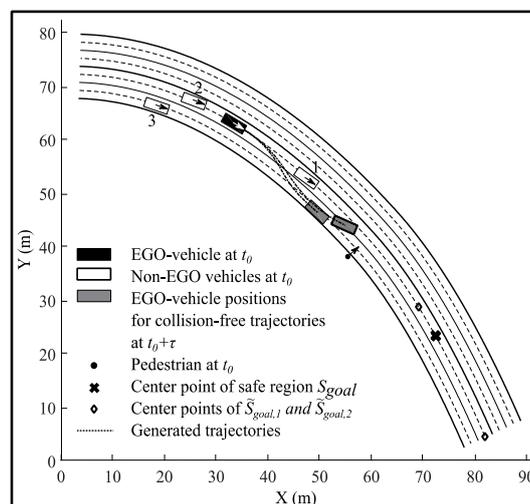


Abbildung 5: Szenario 1 [29]

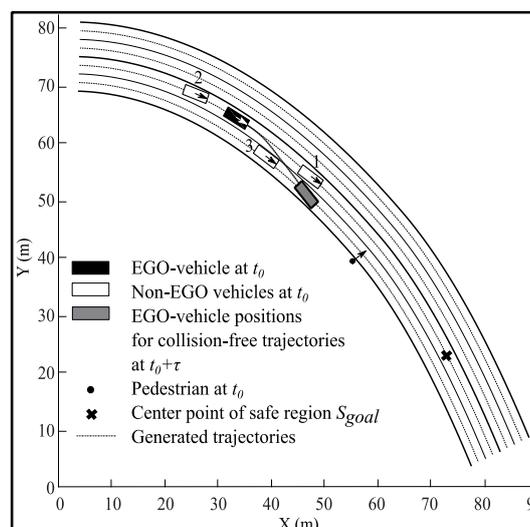


Abbildung 6: Szenario 2 [29]

3) Erstellung Datenbank mit Fahrzeugtrajektorien

Eine große Menge an Daten wurde mit Hilfe der im Projekt implementierten und validierten Simulationsumgebung generiert. Die Daten stellen die Grundlage für die Verwendung der statistischen Lernverfahren für die Trajektorienplanung dar. Abbildung 7 - Abbildung 8 zeigen Beispiele für ein kurvigem Straßen- bzw. Kreuzungsverkehrsszenario, die zur Berechnung von Kollisionsvermeidungstrajektorien mittels maschinellen Lernens verwendet wurden. Es wurden viele Szenarien durch die Variation von Initialzustandswerten wie Position, Geschwindigkeit, Beschleunigung, Radius der Krümmung, usw. generiert. Anschließend wurden für jedes Szenario in der Simulationsumgebung mit dem Augmented CL-RRT und dem Augmented CL-RRT+ Algorithmus Kollisionsvermeidungstrajektorien durch gleichzeitige Lenk- und Bremsmanöver gefunden. Für die Längsdynamik wurden beim Augmented CL-RRT Algorithmus in jedem Szenario 21 vordefinierte Beschleunigungsprofile mit Kombinationen aus Bremsung, Beschleunigung und konstanter Geschwindigkeit bewertet. Die Datengenerierung wurde dabei, wie geplant, von studentischen Hilfskräften durchgeführt.

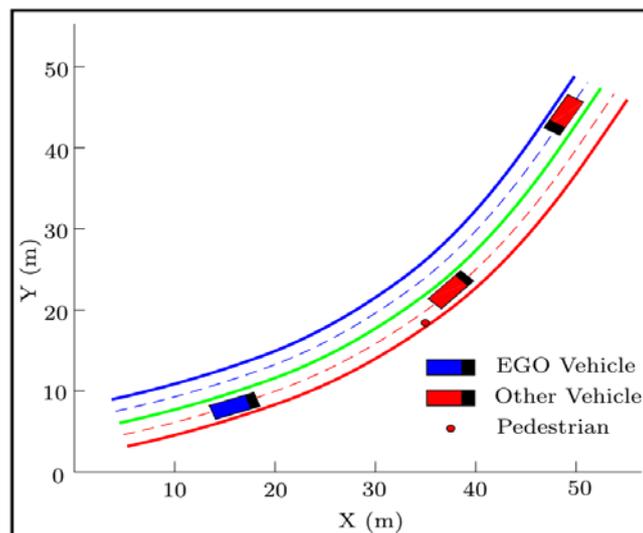


Abbildung 7: Simulierte kurvige Straße [14]

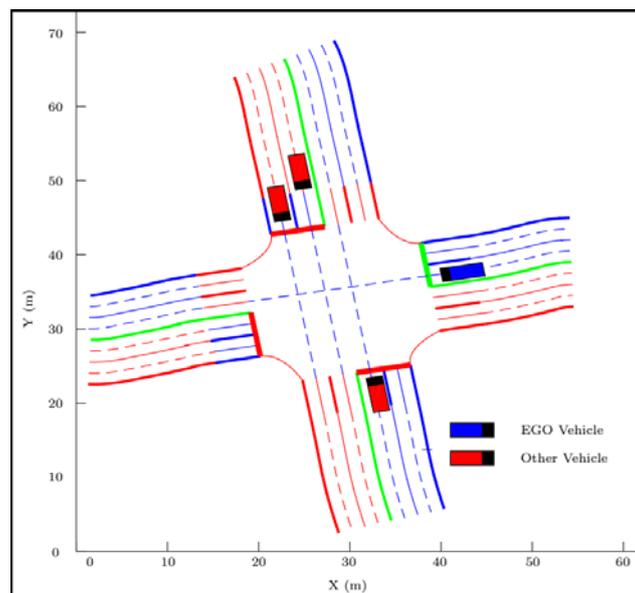


Abbildung 8: Simuliertes Kreuzungsszenario [14]

4) Berücksichtigung Verletzungsschwere in der Trajektorienplanung

Eine Methode für die Berücksichtigung der Verletzungsschwere bei der Trajektorienplanung wurde entwickelt. Dies ist notwendig, da eine Kollisionsvermeidung nicht immer möglich ist und in diesem Fall soll der Algorithmus diejenige Trajektorie finden, bei der die Verletzungsschwere am geringsten ist. Dabei wird die relative Aufprallgeschwindigkeit [30] als wichtiges Maß für die Verletzungsschwere herangezogen. Zusätzlich wurde in die Verletzungsschwere auch der prädizierte Aufprallort (Frontal-, Seiten-, oder Heckkollision) integriert.

AP2: Hybrides Verfahren für die Trajektorienplanung in der Fahrzeugsicherheit

Ziele:

Ziel des AP 2 war es, die Komponenten, die zur Umsetzung der Trajektorienplanung notwendig sind, zu kombinieren und die sich ergebenden Algorithmen simulativ zu validieren.

Aufgabenstellung:

Das zweite Arbeitspaket (AP 2) ist in drei Unter-Arbeitspakete unterteilt. In Unter-Arbeitspaket AP 2.1 sollte die Anforderungserstellung an Module der Trajektorienplanung hinsichtlich der Anwendungen in der Fahrzeugsicherheit erfolgen. Beruhend auf diesen Anforderungen sollte in AP 2.2 die Kombination von statistischen Lernverfahren und physikalischem Modell durchgeführt werden. Hier sollte insbesondere Wert auf das Ziel „geringe Rechenressourcen“ gelegt werden. In AP 2.3 sollte die simulative Bewertung des hybriden statistischen Lernverfahrens erfolgen.

Ergebnisse:

1) Anforderungserstellung für sicherheitskritische Anwendungen

Im Arbeitspaket 2.1 wurden Anforderungen an die Module der Trajektorienplanung in komplexen, dynamischen Verkehrsszenarien hinsichtlich der Anwendungen in der Fahrzeugsicherheit erstellt. Diese Anforderungen lassen sich in funktionale und nicht-funktionale Anforderungen unterteilen [31]. Funktionale Anforderungen an die Module beschreiben, was diese in Bezug auf die gewünschte Funktionalität tun sollen und wurden im „Augmented CL-RRT“ und „Augmented CL-RRT+“ Algorithmus umgesetzt:

- Ein Modul soll die Kritikalität beruhend auf der Prädiktion der Bewegungen anderer Verkehrsteilnehmer schätzen;
- Ein Modul soll fahrbare, kollisionsfreie Trajektorien, die Eingriffe sowohl in die Längs- als auch in die Querdynamik berücksichtigen, berechnen;
- Ein Modul soll pro möglicher Trajektorie die Unfallschwere schätzen;
- Ein Modul soll die beste der berechneten Trajektorien auswählen.

Nicht-funktionale Anforderungen beschreiben Eigenschaften der Module in der Trajektorienplanung und die wichtigsten sind:

- Die Module sollen einen geringen Bedarf an Rechenressourcen haben;
- Die Module sollen interpretierbar sein.

Die Anforderung nach einem geringen Bedarf an Rechenressourcen ergibt sich durch die Notwendigkeit, den Trajektorienplanungsalgorithmus in Echtzeit auf einem Automotive-

μ C laufen zu lassen. Es wurde geplant, diese Anforderung durch den Einsatz von maschinellen Lernverfahren zu realisieren. Die Anforderung der Interpretierbarkeit ergibt sich, gerade beim Einsatz von maschinellen Lernverfahren, durch die Verwendung in sicherheitskritischen Anwendungen. Es wurde geplant diese Anforderung durch eine Kombination des „Augmented CL-RRT“ Algorithmus und maschinellen Lernverfahren zu realisieren und zwar derart, dass die final berechnete Trajektorie durch einen modellbasierten Teil des Algorithmus bestimmt wird.

2) Bewertung und Validierung des hybriden statistischen Lernverfahrens

Im Arbeitspaket 2.2 wurde die nichtfunktionale Anforderung eines geringen Rechenressourcenbedarfs mit Hilfe von maschinellen Lernverfahren umgesetzt. Der „Augmented CL-RRT“ und der „Augmented CL-RRT+“ Algorithmus erfordern das numerische Lösen von Differentialgleichungen in Echtzeit für jedes Objekt in einer Verkehrssituation und für jede einzelne Hypothese des EGO-Fahrzeugs. Der im Projekt verfolgte Ansatz besteht darin, durch maschinelle Lernverfahren eine gezielte Auswahl an geeigneten EGO-Trajektorien für jede Verkehrssituation zu machen und damit die Anzahl der Hypothesen für das EGO-Fahrzeug, für die Differentialgleichungen in Echtzeit gelöst werden müssen, deutlich zu senken.

Beim Augmented CL-RRT werden erhebliche Ressourcen benötigt, da viele Beschleunigungsprofile für das EGO Fahrzeug betrachtet werden. Mit Hilfe der in AP1 generierten Daten wurden „Convolutional-Neural-Networks“ (CNN) trainiert, um damit statt einer großen Anzahl an EGO-Hypothesen für die Längsdynamik nur noch die geeignetsten 3 im „Augmented CL-RRT“ zu nutzen. Diese Methode des hybriden maschinellen Lernens (Kombination von „3D-ConvNet Methode“ und „Augmented CL-RRT“) hat sich als erfolgreich herausgestellt und wurden auf der IEEE International Conference on Machine Learning and Applications (IEEE ICMLA'16) im Dezember 2016 in Anaheim, California veröffentlicht. Es stellte sich heraus, dass durch den Einsatz von maschinellen Lernverfahren die Laufzeit um den Faktor 8,1 in kurvige Straßen und 5,1 in Kreuzungen reduziert werden kann, ohne die Performance beim Finden von sicheren Trajektorien zu verschlechtern. Tabelle 1 stellt die Ergebnisse aus der Veröffentlichung dar.

Tabelle 1: Vergleich zwischen Augmented CL-RRT und Hybrid Augmented CL-RRT Algorithmus

Kriterien	Kurvige Straßen		Kreuzungen	
	Aug. CL-RRT	Hybrid Aug. CL-RRT	Aug. CL-RRT	Hybrid Aug. CL-RRT
Durchschnittliche Anzahl der Knoten	1272	109	1868	237
Durchschnittliche Zeit (Sek.)	5,0518	0,6230	6,6989	1,3126
Gefundene kollisionsfreie Trajektorien (%)	100	99,63	60,85	51,95
Sichere Trajektorie nicht gefunden (%)	0	0	0	5,58

Beim Augmented CL-RRT+ Algorithmus wurde nicht nur auf vordefinierte Beschleunigungsprofile, sondern auch auf zufällige und physikalisch mögliche Längsbeschleunigungen zurückgegriffen. Der Vorteil dieses Ansatzes ist, dass die resultierenden Trajektorien auch in der Längsdynamik mehr Varianz aufweisen können und somit kollisionsfreie

Trajektorien auch in hochkomplexen Situationen mit vielen dynamischen Objekten gefunden werden können, wo dies mit Augmented CL-RRT nicht möglich war. Um die Eignung des Augmented CL-RRT+ Algorithmus zu analysieren, wurden viele Verkehrsszenarien simuliert und sichere Trajektorien mit beiden Algorithmen gefunden. Tabelle 2 zeigt die Ergebnisse des Vergleichs.

Tabelle 2: Vergleich zwischen Augmented CL-RRT und Augmented CL-RRT+ Algorithmus

Kriterien	Szenarien mit 4 Objekten (405 Szenarien)		Szenarien mit 6 Objekten (478 Szenarien)	
	Aug. CL-RRT	Aug. CL-RRT+	Aug. CL-RRT	Aug. CL-RRT+
Durchschnittliche Anzahl der Knoten	595	210	629	201
Durchschnittliche Zeit (Sek.)	6,11	3,59	6,76	4,19
Gefundene kollisionsfreie Trajektorien (%)	98,76	96,79	77,84	90,37
Sichere Trajektorie nicht gefunden (%)	0	0	0,05	0,09

Die statistischen Lernmethoden werden verwendet, um Lenkradwinkel- und Beschleunigungsprofile vorherzusagen, die dann genutzt werden, um eine schnellere Konvergenz des Augmented CL-RRT+ Algorithmus zu ermöglichen. Diese Kombination aus statistischem Lernalgorithmus und Augmented CL-RRT+ Algorithmus, die Hybrid Augmented CL-RRT+ genannt wurde, führt zu einer durchschnittlichen vierfachen Reduzierung der Rechenzeit. Dies ist in der Tabelle 3 zu sehen. Die Beiden Methoden, Augmented CL-RRT+ und Hybrid Augmented CL-RRT+, wurden auf der IEEE Intelligent Vehicle Symposium (IVS' 17) im Juni 2017 veröffentlicht.

Tabelle 3: Vergleich zwischen Augmented CL-RRT+ und Hybrid Augmented CL-RRT+ Algorithmus

Kriterien	Testdaten für trainierte Kurven (994 Szenarien)		Testdaten für nicht trainierte Kurven (403 Szenarien)	
	Aug. CL-RRT+	Hybrid Aug. CL-RRT+	Aug. CL-RRT+	Hybrid Aug. CL-RRT+
Durchschnittliche Anzahl der Knoten	163	101	186	112
Durchschnittliche Zeit (Sek.)	4,06	1,03	4,26	1,27
Gefundene kollisionsfreie Trajektorien (%)	96,5	95,83	96,66	90,60
Sichere Trajektorie nicht gefunden (%)	0	0,80	0,99	1,74

AP3: Embedded Umsetzung

Ziele:

Ziel des AP 3 war es, die Algorithmen, die mittels hybriden statistischen Lernverfahren entworfen wurden, auf einem Automotive- μ C umzusetzen und deren Ressourcenverbrauch zu analysieren.

Aufgabenstellung:

Das dritte Arbeitspaket (AP 3) ist in zwei Unter-Arbeitspakete unterteilt. Hier sollte die Umsetzung des statistischen Lernverfahrens zur Trajektorienplanung auf einem Automotive- μ C stattfinden. In Unter-Arbeitspaket AP 3.1 sollte die Portierung der Algorithmen auf einen Automotive- μ C erfolgen. Dabei sollte der WPK-Partner ASTech mit seinem Fachwissen im Bereich Automotive-Software, insbesondere bei der Wahl der geeigneten Hardware und der dazu notwendigen Tools unterstützen. In AP 3.2 sollten die beiden Ressourcen Speicher und Laufzeit der Trajektorienplanung auf dem Automotive- μ C gemessen und analysiert werden.

Ergebnisse:

1) Umsetzung der Algorithmen auf einem Automotive- μ C

Für die Embedded-Implementierung der Algorithmen wurden zwei Starter-Kits Texas Instrument TMS570 und Raspberry Pi 3 gekauft. Darüber hinaus wurde eine Rapid Prototyping Hardware, die Microautobox, vom WPK-Partner zur Verfügung gestellt. Die Algorithmen wurden in der Matlab-Simulationsumgebung entwickelt. Deswegen wurde die Matlab-Toolbox „Simulink Coder“ verwendet, um Matlab-Code in optimierten C-Code zu konvertieren, der auf alle Hardware-Plattformen heruntergeladen werden kann. Code-Compiler für die eingesetzten Hardware-Plattformen und deren Schnittstellen zu Matlab waren verfügbar. Somit konnte der generierte Code auf alle Hardwareplattformen heruntergeladen werden.

2) Messung und Bewertung der benötigten Ressourcen (Speicher und Laufzeit)

In einem ersten Schritt wurde der Matlab-Code für die Algorithmen „Augmented CL-RRT“ und „Hybrid Augmented CL-RRT“ so modifiziert, dass sie für die Code Konvertierung mit dem Simulink Coder kompatibel werden. In Matlab haben alle Variablen den Datentyp „Double“, der mehr Speicherplatz benötigt. Daher wurden für alle Variablen geeignete Datentypen definiert, damit der Speicher nicht verschwendet wird. Nach dieser Konvertierung wurde festgestellt, dass der SRAM-Speicherbedarf für beide Algorithmen hoch war und nicht auf den Texas Instrument TMS570 Mikrocontroller, der nur 160 KB SRAM hat, heruntergeladen werden konnte. Daher wurden zusätzliche Optimierungsschritte durchgeführt, um den SRAM-Speicherbedarf und die Rechenzeit des hybriden Trajektorienplanungsalgorithmus zu reduzieren. Die Module, die erhebliche Anteile der Rechenzeit und SRAM-Speicher benötigen, wurden identifiziert und alternative maschinelle Lern- oder analytische Methoden zur Optimierung der Rechenressourcen eingesetzt. Tabelle 4 zeigt die in verschiedenen Hardwareplattformen benötigten Rechenressourcen.

Tabelle 4: Benötigte Rechenressourcen für Trajektorienplanungsalgorithmen

Methode	SRAM (KB)	TMS570 (ms)	Microautobox (ms)	Raspberry Pi (ms)
Augmented CL-RRT	374,013	NA	340	800
Hybrid Augmented CL-RRT	812,303	NA	98	290
Optimized Hybrid Augmented CL-RRT	158,893	423,2	19	140

AP4: Darstellung im Fahrzeug und Validierung

Ziele:

Ziel des AP 4 war es, die Algorithmen, die mittels hybriden statistischen Lernverfahren entworfen wurden, in einem Fahrzeug auf dem Testgelände zu validieren.

Aufgabenstellung:

Das vierte Arbeitspaket (AP 4) ist in zwei Unter-Arbeitspakete unterteilt. AP 4 umfasst die demonstratorische Integration des hybriden Modells zur Trajektorienplanung in einem Fahrzeug und dessen Validierung auf einem Testgelände. In Unter-Arbeitspaket AP 4.1 sollte der Automotive- μ C an ein Fahrzeug angeschlossen und seine Inbetriebnahme erfolgen. Für dieses Arbeitspaket sollte der WPK-Partner ASTech ein Fahrzeug zur Verfügung stellen und mit seiner Erfahrung die notwendigen Integrationsschritte unterstützen. In AP 4.2 sollte die Validierung der Trajektorienplanung mittels hybrider statistischer Lernmethoden in unterschiedlichen Verkehrsszenarien auf einem Testgelände stattfinden.

Ergebnisse:

1) Einbindung Mikrocontroller im Fahrzeug und Validierung der Algorithmen

In AP 4 war die Validierung hybrider statistischer Lernalgorithmen mit einem Fahrzeug auf einer Teststrecke geplant. Es hat sich herausgestellt, dass dieser Schritt komplexer war, als in der ursprünglichen Planung angenommen wurde. Nachdem sich die Umsetzung in einem speziellen Versuchsträger der Firma ASTech aufgrund der Verfügbarkeit als nicht zielführend herausgestellt hat, wurden die Versuche mit Hilfe eines Fahrroboters auf dem Freiversuchsgelände des Forschungszentrums CARISSMA realisiert. Der Fahrroboter ist in der Lage, die Trajektorien der Algorithmen durch Brems-/Beschleunigungs- oder Lenkbefehle in einem „normalen“ Fahrzeug in Echtzeit darzustellen. Die Umsetzung dieser Steuerung des Fahrzeugs durch einen Fahrroboter, um die Validierung der Algorithmen in realen Fahrversuchen zu ermöglichen, führte zu einer Verzögerung von ca. 2,5 Monaten. Um das endgültige Arbeitspaket 4.2 in der ursprünglich geplanten Tiefe durchzuführen, wurde das Projekt bis Januar 2018 verlängert. Die Architektur aus der Abbildung 9 wurde entwickelt, um die Algorithmen auf der Teststrecke zu testen.

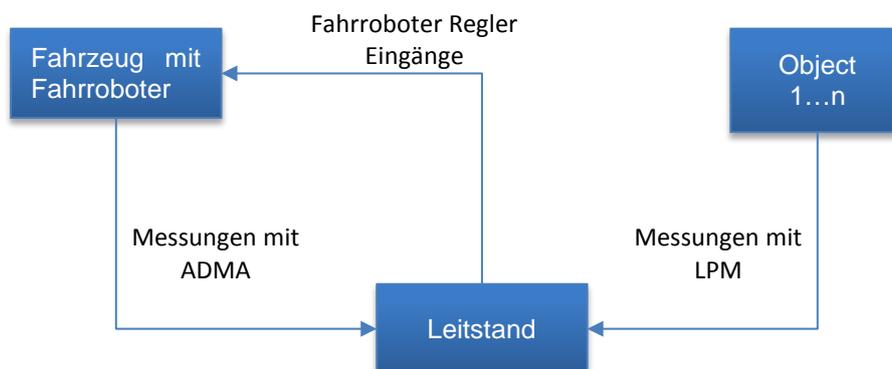


Abbildung 9: Architektur zum Testen von Algorithmen mit Fahrzeug

Die Fahrzustände des EGO Fahrzeugs und der anderen Objekte eines Testszenarios werden über WiFi an einen Rechner im Leitstand übertragen. Die Fahrzeugzustände werden mittels eines inertialen Messsystems, ADMA, und eines Positionierungssystems, LPM, ermittelt. ADMA verwendet ein differentielles GPS und LPM ist ein radarbasiertes

Positionsbestimmungssystem. Beide sind an der THI verfügbar. Diese Messungen werden als Eingang für die hybriden statistischen Lernalgorithmen in die gewünschte Form gebracht und eine sichere Trajektorie auf dem Rechner im Leitstand berechnet. Die berechnete Trajektorie wird in Form von Ortspunkten mit dazugehörigen Geschwindigkeitswerten über WiFi an den Fahrroboter gesendet.

2) Validierung der Algorithmen auf dem Testgelände

Mit der oben genannten Architektur wurden einige Verkehrsszenarien auf der Teststrecke realisiert. Wenn das EGO-Fahrzeug sich in einem, mit Attrappen realisierten, kritischen Verkehrsszenario befindet, berechnet der hybride statistische Lernalgorithmus eine sichere Trajektorie im Computer (Leitstand) basierend auf der aktuellen Verkehrssituation rund um das EGO-Fahrzeug. Diese Trajektorie wird mit Hilfe des Fahrroboters vom EGO-Fahrzeug umgesetzt, um eine Kollision zu vermeiden. Die Tests wurden nur mit geringen Geschwindigkeiten (30 km/h) umgesetzt, bestätigen aber, dass eine sichere Trajektorienplanung mit hybriden statistischen Lernmethoden auch in realen Verkehrsszenarien funktioniert. Die Abbildung 10 und Abbildung 11 zeigen den verwendeten Fahrroboter und die Realisierung einer kritischen Verkehrssituation mittels Attrappen auf dem CARISSMA-Freiversuchsgelände.



Abbildung 10: Fahrzeug mit montiertem Fahrroboter



Abbildung 11: Kritische Verkehrssituation mittels Attrappen auf dem CARISSMA-Freiversuchsgelände

2. Erläuterung der wichtigsten Positionen im zahlenmäßigen Nachweis

Im Projekt HySLEUS entstand der größte Teil der Kosten durch Personalausgaben (wissenschaftlicher Mitarbeiter und studentische Hilfskraft). An zweiter Stelle folgten die Ausgaben für Dienstreisen, gefolgt von den Investitionen >400 Euro, die im wesentlichen durch die Anschaffung von 1 Workstation und 2 Mikrocontrollern entstanden.

Tabelle 5: Ausgaben

Kostenart	Ausgaben (Euro)
Wissenschaftlicher Mitarbeiter	234.595,36
Studentische Hilfskräfte	14.519,28
Dienstreisen	5.403,58
Investitionen > 400 Euro	2584,65

Abbildung 12 stellt die Ausgaben im Projekt HySLEUS graphisch dar.



Abbildung 12: Ausgaben

3. Notwendigkeit und Angemessenheit der geleisteten Arbeit

Die Trajektorienplanung zur Kollisionsvermeidung bzw. Minderung der Unfallfolgen in kritischen, dynamischen Verkehrsszenarien unter Berücksichtigung fahrdynamischer Randbedingungen ist eine wichtige Aufgabe, um automatisiertes Fahren zu ermöglichen. Dieses Problem ist aufgrund der Komplexität möglicher Szenarien im Straßenverkehr eine große Herausforderung und ist immer noch Gegenstand unterschiedlicher Forschungsansätze. Darüber hinaus müssen die dafür notwendigen Algorithmen in Echtzeit auf ressourcenbeschränkten Automotive- μ C laufen. Im Projekt wurde eine Methode erarbeitet, umgesetzt und validiert, um diesen wichtigen algorithmischen Baustein des automatisierten Fahrens zu realisieren.

Statistische Lernmethoden bieten die Möglichkeit, schnell Lösungen für komplexe Aufgaben zu finden, sind aber rein datenbasierte Methoden und werden als Blackbox betrachtet. In sicherheitskritischen Anwendungen, wie der Trajektorienplanung, ist das genaue Verständnis der Modelle, die die Akteure steuern, d.h. die Interpretierbarkeit von Entscheidungen, die von Algorithmen getroffen werden, besonders wichtig für den Validierungs- und die Absicherungsprozess. Aus diesem Grund ist die Verwendung von fahrdynamischen Modellen besonders wichtig für Anwendungen wie die Trajektorienplanung. Der Nachteil dieser Modelle ist, dass sie hohe Rechenressourcen benötigen, um in Echtzeit zu laufen, und die Berechnung vieler Hypothesen für unterschiedliche Objekte in einem Multi-Objekt Szenario im Fahrzeug nicht möglich ist.

Hybride statistische Lernmethoden, die eine Kombination aus statistischen Lernmethoden und physikalischen Modellen sind, eröffnen eine neue Möglichkeit, maschinelle Lernalgorithmen in sicherheitskritischen Anwendungen einzusetzen. Im HySLEUS-Projekt wurde diese Kombination so eingesetzt, dass maschinelle Lernalgorithmen verwendet werden, um eine Näherungslösung zu finden und diese eine schnelle Konvergenz modellbasierter Algorithmen ermöglicht. Die finale Trajektorie ist damit das Ergebnis einer modellbasierten Trajektorienplanung, aber das Finden dieser Lösung beruht auf maschinellen Lernalgorithmen.

Als modellbasierter Ansatz für die Trajektorienplanung wurden Varianten eines auf Zufallsstichproben basierenden Algorithmus entwickelt. Die Wahl dieses Algorithmus hatte zwei Gründe. Erstens werden fahrdynamische Randbedingungen für die Trajektorienplanung berücksichtigt, so dass sie fahrbare Trajektorien erzeugen. Zweitens ist es ein probabilistisch vollständiger Ansatz, d. h. es wird garantiert, dass eine Lösung gefunden wird, wenn sie existiert. Diese Vorteile ermöglichen eine einheitliche Trajektorienplanung für alle Arten von Verkehrsszenarien. Einziger Nachteil bei diesem Algorithmus ist, dass er aufgrund von Zufallsstichproben eine hohe Rechenzeit benötigt. Daher werden maschinelle Lernalgorithmen verwendet, um Näherungslösung zu erzeugen, so dass die Konvergenzgeschwindigkeit der Algorithmen stark erhöht wird. Die Eingangsmerkmale für die verwendeten maschinellen Lernalgorithmen sind prognostizierte Belegungskarten, deren Dimension unabhängig von der Straßeninfrastruktur, Art und Anzahl der Verkehrsteilnehmer gleich bleibt. Deswegen kann auch die Berechnung der Näherungslösung mittels maschinellem Lernen für alle Arten von Verkehrsszenarien verwendet werden.

Der vorgeschlagene Ansatz der Kombination von maschinellen Lernalgorithmen und modellbasierten Bahnplanungsalgorithmen ermöglicht es, statistische Lernverfahren in sicherheitskritischen Anwendungen einzusetzen, wobei die Interpretierbarkeit der Algorithmen durch die Verwendung fahrdynamischer Modelle, um die endgültige Lösung zu finden, beibehalten wird. Durch diese Vorgehensweise wurden gleich zwei wichtige Problemstellungen im Projekt gelöst: eine erhebliche Reduktion der Rechenressourcen und die Absicherungs- bzw. interpretierbare Validierung eines Verfahrens, das maschinelle Lernalgorithmen nutzt.

Das Vorgehen ist auch auf andere Fragestellungen der Fahrzeugsicherheit bzw. anderer sicherheitskritischer Systeme übertragbar. Gerade mit der ständig ansteigenden Anzahl an Anwendungen, in denen maschinelles Lernen eine zunehmende Bedeutung hat, sind Möglichkeiten der Kombination mit modellbasierten Ansätzen von zentraler Bedeutung.

Zum einen wird bereits vorhandenes Wissen in Form von Modellen genutzt und muss nicht aus Daten erlernt werden und zum anderen kann das Problem der Absicherung bzw. der interpretierbaren Validierung von maschinellen Lernalgorithmen, so wie in diesem Projekt vorgestellt, angegangen werden.

4. Voraussichtlicher Nutzen und Verwertbarkeit des Ergebnisses (Fortschreibung des Verwertungsplanes)

Nutzen aus Sicht der ASTech GmbH

Der WPK-Partner ASTech GmbH hat seit Beginn des Projekts eine Gruppe für maschinelles Lernen gegründet und beabsichtigt, hybride maschinelle Lernverfahren für unterschiedliche Anwendungen zu nutzen. Das Projekt HySLEUS hat dabei Möglichkeiten aufgezeigt, wie maschinelle Lernalgorithmen mit modellbasierten Ansätzen kombiniert werden können. Der im Projekt entwickelte Trajektorienplanungsalgorithmus kann bei entsprechendem Bedarf in Produkte des WPK-Partners integriert oder als Referenzalgorithmus verwendet werden. Für diesen Zweck wurde über eine Lehrbeauftragung eines ASTech-Mitarbeiters an der THI im Bachelor-Studiengang „Flug- und Fahrzeuginformatik“ ein Projekt mit dem Titel "Funktionale Absicherung von Algorithmen des HySLEUS-Projekts nach ISO26262:2011" im Wintersemester 2017/2018 angeboten.

Nutzen aus Sicht der THI

HySLEUS ist das erste Forschungsprojekt des Projektleiters an der THI und stellt die Grundlage für seine inzwischen auf 8 wissenschaftliche Mitarbeiter angewachsene Arbeitsgruppe, die sich mit maschinellem Lernen für die Fahrzeugsicherheit beschäftigt, dar. Die erfolgreiche Bearbeitung von HySLEUS, der damit verbundene Know-how Aufbau und die internationalen Publikationen in HySLEUS haben die Akquise von weiteren öffentlich geförderten und industriefinanzierten Forschungsprojekten möglich gemacht.

Umfänge, die in anderen Forschungsprojekten entwickelt werden, können mit den Ergebnissen aus HySLEUS kombiniert werden, wodurch ein zusätzlicher Know-how-Aufbau für die Verwendung von maschinellen Lernmethoden in der Fahrzeugsicherheit erreicht wird. So wurde beispielsweise in einem anderen Projekt der Arbeitsgruppe ein maschineller Lernalgorithmus zur Vorhersage eines dynamischen Verkehrsszenarios entwickelt, der effizienter ist als die modellbasierte Vorhersage in HySLEUS. Es ist geplant diese Vorhersagemethode dynamischer Objekte mit den hybriden maschinellen Lernansätzen aus dem HySLEUS Projekt zur Trajektorienplanung zu kombinieren.

Die im HySLEUS Projekt entwickelten Algorithmen nutzen offline generierte Daten in der Simulation für die Lernaufgabe. Es ist geplant, diese Methodik zu einem Online-Ansatz des maschinellen Lernens weiterzuentwickeln, der das Fahrerverhalten in verschiedenen Verkehrssituationen vom Fahrer lernt. Dafür wurde vom Projektleiter ein Antrag mit dem Namen „Online Maschinelles Lernen in Anwendungen der Fahrzeugsicherheit“ (OLAF) im Rahmen des bayerischen Landesforschungsprogramms gestellt und dieser Antrag war erfolgreich. Das Forschungsprojekt OLAF wird im August 2018 starten. Die im Rahmen von HySLEUS gewonnenen Erkenntnisse werden von großem Nutzen dafür sein.

Im HySLEUS-Projekt wurden wie geplant zwei Master- und zwei Bachelorarbeiten abgeschlossen und die Promotion eines wissenschaftlichen Mitarbeiters steht noch bevor. Wie bereits oben erwähnt ist Letzterer in der Graduate School der TUM eingeschrieben und seine Promotion ist im Jahr 2019 zu erwarten. Einer der Masterstudenten aus dem HySLEUS-Projekt arbeitet weiterhin im Rahmen des Forschungszentrums CARISSMA mit dem Projektleiter zusammen. Viele studentische Hilfskräfte sammelten Erfahrungen bei verschiedenen Aufgaben im HySLEUS-Projekt und haben damit Einblicke in die Forschungsaktivitäten erhalten. Der wissenschaftliche Mitarbeiter in HySLEUS hat auch ein Matlab-Tutorium im Rahmen des Master-Kurses „Integrated Safety and Assistance Systems“ an der THI angeboten. Der Projektleiter hat Erkenntnisse aus dem Forschungsprojekt HySLEUS bzgl. der Trajektorienplanung in kritischen Verkehrssituationen in die Master-Kurse „Integrated Safety and Assistance Systems“ und „Sensor Technology and Signal Processing“ einfließen lassen.

Im Projekt wurde ein Betrag für die Anmeldung einer Erfindung vorgesehen. Eine Beschreibung der Erfindung wurde verfasst und der Bayrischen Patentallianz GmbH (BayPat) zur Beurteilung der Patentierbarkeit und Marktfähigkeit vorgelegt. Das Feedback bestätigt die Neuartigkeit der im Projekt vorgestellten Ideen, doch werden Bedenken hinsichtlich der Patentierbarkeit auf der Grundlage der bereits im Projekt veröffentlichten Ergebnisse geäußert. Daher wurde die Patentanmeldung nicht vorgetragen.

5. Fortschritte auf dem Gebiet des Vorhabens bei anderen Stellen während der Durchführung

Wie bereits erwähnt, gibt es viele in der Literatur vorgeschlagene Algorithmen zur Trajektorienplanung von Robotern. Diese Algorithmen sind jedoch angesichts der Komplexität möglicher Verkehrssituationen nicht in der Lage, kollisionsfreie Trajektorien mit gleichzeitigem Eingriff in die Fahrzeuglängs- und Querdynamik in Echtzeit zu finden. Im HySLEUS-Projekt wurde der Ansatz des hybriden maschinellen Lernens zur Lösung dieses Problems gewählt. Ansätze, die zeitgleich entwickelt wurden und die diese Aufgabe mit reinen modellbasierten Algorithmen zu lösen versuchen sind in [32] und [33] zu finden.

Während der Laufzeit des Projekts wurden auch von anderen Wissenschaftlern Ansätze untersucht, um durch maschinelle Lernverfahren die Trajektorienplanungsalgorithmen auf unterschiedliche Weise zu unterstützen. Eine erlernte Gaussian Mixture Models-Verteilung wurde beispielsweise für das Biased-Sampling in gelernten Freiräumen verwendet [34], um die Anzahl der Kollisionsprüfungen für die Trajektorienplanung mit dem RRT-Algorithmus drastisch zu reduzieren. Die Arbeit in [35] verwendet einen „Conditional Variational Autoencoder“, um aus einer gelernten Sampling-Verteilung verzerrte Samples im Raum zu erzeugen und die Konvergenzrate des RRT-Algorithmus zu erhöhen. Beide Ansätze führen jedoch nur ein Biased-Sampling im Raum durch, während die im HySLEUS-Projekt entwickelten Algorithmen einen Biased-Sampling-Ansatz für Raum und Zeit vorschlagen.

Während der Laufzeit des Projekts hat NVidia einen „end-to-end learning“ Ansatz vorgeschlagen [36], der das Bild der Straße als Eingang für neuronale Netze verwendet und Lenkwinkelwerte ausgibt. In der Veröffentlichung wird auch eine Möglichkeit vorgestellt wie ermittelt werden kann, welche Bereiche des Eingangsbildes für eine Entscheidung

relevant sind. Allerdings handelt es sich um einen Ansatz, der im Gegensatz zum Vorgehen im HyLEUS Projekt, nicht absicherbar ist und damit ungeeignet für sicherheitskritische Anwendungen.

6. Geplante und erfolgte Veröffentlichungen im Rahmen des Vorhabens

Die Ergebnisse des HySLEUS-Projektes wurden und werden, wie nachfolgend aufgeführt, im Rahmen von Fachartikeln in Zeitschriften und Tagungsbänden, Präsentationen auf nationalen und internationalen Tagungen sowie durch die im Rahmen des Projekts entstandene Dissertation präsentiert.

Liste der im Projektzeitraum erfolgten Veröffentlichungen (peer-reviewed):

1. A. Chaulwar, M. Botsch, T. Krüger, T. Miehling, „Planning of safe trajectories in dynamic multi-object traffic-scenarios“, Journal of Traffic and Logistics Engineering, Vol. 4, 2016.
2. A. Chaulwar, M. Botsch, W. Utschick, „A hybrid machine learning approach for planning safe trajectories in complex traffic-scenarios“, International Conference on Machine Learning and Applications, 2016.
3. A. Chaulwar, M. Botsch, W. Utschick, „A machine learning based biased-sampling approach for planning safe trajectories in complex, dynamic traffic-scenarios“, IEEE Intelligent Vehicle Symposium, 2017.
4. A Chaulwar, M. Botsch, W. Utschick, “Generation of Reference Trajectories for Safe Trajectory Planning”, International Conference on Artificial Neural Networks, 2018.

Liste der im Projektzeitraum erfolgten Abschlussarbeiten:

1. Modeling of Motion Hypotheses for Traffic Participants in the Path-Planning Task
2. Probabilistic Planning of Safe Trajectories in Dynamically Uncertain and Critical Road-Traffic Scenarios
3. Crash Severity Estimation Based on an Occupant Movement Model
4. Wireless Control of Full Scale Autonomous Maneuvering System using DiGi XBee Series 1 Modules and MATLAB.

Liste der im Projektzeitraum erfolgten Poster Präsentationen:

1. BMW Summer School, Bad Wörishofen, 2017
2. ACM Chapters Computer Science in Cars Symposium, 2017.

Geplante Dissertation:

Hybrid Statistical Learning Methods for Vehicle Safety Applications

Geplante Veröffentlichung in einer Zeitschrift:

Efficient Embedded-Implementation of Hybrid Machine Learning Methods for Vehicle Trajectory Planning

III. Erfolgskontrollbericht

Siehe Anlage.

IV. Kurzfassung/Berichtsblatt

Siehe Anlage.

E. Literaturverzeichnis

- [1] R. M. S. Waydo, „Vehicle Motion Planning with Stream Functions,“ in *International Conference on Robotics and Automation*, 2003.
- [2] S. T. M. M. a. J. D. D. Doglov, „Path Planning for Autonomous Vehicles in Unknown Semistructured Environments,“ *International Journal of Robotics Research*, Bd. 5, pp. pp. 485-501, 2010.
- [3] Y. Kuwata, „Real-Time Motion Planning with Applications to Autonomous Urban Driving,“ in *IEEE Transactions on Control Systems Technology*, 2009.
- [4] M. L. a. M. S. K. Chu, „Local Path Planning for Off-Road Autonomous Driving with Avoidance of Static Obstacles,“ in *IEEE Transactions on Intelligent Transportation Systems*, 2012.
- [5] M. H. a. R. B. D. Schramm, *Modellbildung und Simulation der Dynamik von Kraftfahrzeugen*, Berlin: Springer Verlag, 2010.
- [6] R. Isermann, *Fahrdynamik Regelung*, 2006: Vieweg.
- [7] X. R. L. a. P. V. Jikov, „Survey of Maneuvering Target Tracking,“ in *IEEE Transactions on Aerospace and Electronic Systems*, 2003.
- [8] K. L. a. S. S. M. Buehler, „The Darpa Urban Challenge: Autonomous Vehicle in City Traffic,“ *Springer*, 2010.
- [9] K. L. a. S. S. M. Buehler, „The 2005 Darpa Grand Challenge,“ *Springer Tracts in Advanced Robotics*, 2007.
- [10] K. D. Dusano, *Methodology for Determining Crash and Injury Reduction from Emerging Crash Prevention Systems in U. S.*, Virginia Polytechnic Institute and State University, 2013.
- [11] F. K. a. A. Engeln, „Autonomous Emergency Braking,“ *ATZautotechnology*, Bd. 5, pp. 38-43, 2010.
- [12] A. S. M. Mohanan, „A survey of robotic motion planning in dynamic environments Robotics and Autonomous Systems,“ in *10.1016/j.robot.2017.10.011*, 2017.
- [13] R. K. e. el., „Real-Time Motion Planning With Applications to Autonomous Urban Driving,“ in *IEEE Transaction on Control Systems Technology*, 2009.
- [14] M. B. W. U. A. Chaulwar, „A Hybrid Machine Learning Approach for Planning Safe Trajectories in Complex Traffic-Scenarios,“ in *IEEE International Conference of Machine Learning and Applications*, 2016.
- [15] M. B. W. U. A. Chaulwar, „A Machine Learning Based Biased-Sampling Approach for Planning Safe Trajectories in Complex, Dynamic Traffic-Scenarios,“ in *IEEE Intelligent Vehicle Symposium*, 2017.
- [16] R. Isermann, *Fahrdynamik-Regelung: Modelbildung, Fahrassistenzsysteme, Mechatronik*, Vieweg-Teubner Verlag, 2006.
- [17] J. L. S. Y. D. Kim, „Cloud RRT*,“ in *International Conference on Robotics and Automation*, 2014.
- [18] „Batch Informed Trees (BIT*): Sampling-based optimal planning via the heuristically guided search of implicit random geometric graphs,“ in *International Conference on Robotics and Automation*, 2015.
- [19] A. S. J. W. J. D. J. B. C. C. Jurewicza, „Exploration of Vehicle Impact Speed–Injury Severity Relationships for Application in Safer Road Design,“ in *Transportation research procedia*, 2016.

- [20] P. N. M. B. M. Müller, W. Utschick, D. Böhmländer und S. Katzenbogen, „A statistical learning approach for estimating the reliability of crash severity predictions crash severity predictions,“ in *IEEE Intelligent Transportation Systems*, 2016.
- [21] [Online]. Available: <https://www.km.bayern.de/allgemein/meldung/4110/bayerische-hochschulen-beschreiten-neue-wege-der-zusammenarbeit.html>. [Zugriff am 25 06 2018].
- [22] E. Schindler, „Fahrodynamik: Grundlagen des Lenkverhaltens und ihre Anwendung für Fahrzeugsicherheit,“ *expert Verlag*, 2011.
- [23] J. A. L. N. K. Lundahl, „Investigating Vehicle Model Detail for Close to Limit Maneuvers Aiming at Optimal Control,“ in *International Symposium on Dynamics of Vehicles on Roads and Tracks*, Manchester, United Kingdom, 2011.
- [24] M. E. B. Heißing, *Fahrwerkhandbuch: Grundlagen, Fahrodynamik, Komponenten, Systeme, Mechatronik, Perspektiven*, Vieweg-Teubner Verlag, 2007.
- [25] E. R. G. W. R. Schubert, „Comparison and Evaluation of Advanced Motion Models for Vehicle Tracking,“ in *International Conference of Information Fusion*, 2008.
- [26] N. N. B. R. P. Hart, „A Formal basis for the Heuristic Determination of Minimum Cost Paths,“ *IEEE Transactions on System Science and Cybernetics*, Bd. 4, pp. 100-107, 1968.
- [27] A. Stenz, „Optimal and Efficient Path Planning for Partially-Known Environments,“ in *International Conference on Robotics and Automation*, 1994.
- [28] S. L. J. Kuffner, „Rrt-connect: An Efficient Approach to Single-Query Path Planning,“ in *International Conference on Robotics and Automation*, 2000.
- [29] M. B. T. K. T. M. A. Chaulwar, „Planning of Safe Trajectories in Dynamic Multi-Object Traffic-Scenarios,“ *Journal of Traffic and Logistics Engineering*, Bd. 4, Nr. 2, 2016.
- [30] A. S. J. W. B. C. C. Jurewicz, „Proposed Vehicle Impact Speed- Severe Injury Probability Relationships for Selected Crash Types,“ in *Australian Road Safety Conference*, 2015.
- [31] M. Palumbo, „Requirement Management for Safety Critical Systems,“ [Online]. Available: <http://www.railwaysignalling.eu/requirements-management-safety-critical-systems>. [Zugriff am 25 06 2018].
- [32] E. F. M. Otte, „Real-Time Motion Planning/Replanning for Environments with Unpredictable Obstacles,“ in *International Workshop on the Algorithmic Foundations of Robotics*, 2014.
- [33] J. L. Y. H. M. T. W. Zhan, „Safe and Feasible Motion Generation for Autonomous Driving via Constrained Policy Net,“ in *IEEE Intelligence Vehicles Symposium*, 2017.
- [34] D. L. J. Huh, „Learning High Dimensional Mixture Models for Fast Collision Detection in Rapidly-Exploring Random Trees,“ in *IEEE International Conference on Robotics and Automation*, 2016.
- [35] J. H. M. P. B. Ichter, „Learning Sampling Distribution for Robot Motion Planning,“ in *IEEE International Conference of Robotics and Automation*, 2018.
- [36] M. B. e. el., „Explaining How a Deep Neural Network Trained with End-to-End Learning Steers a Car,“ in *arXiv preprint arXiv:1604.07316*, 2017.
- [37] R. S. C. Urmsons, „Approaches for Heuristically Biasing RRT Growth,“ in *IEEE International Conference on Intelligent Robots and Systems*, 2003.
- [38] E. B. W. R. S. Kiesel, „Abstraction Guided Sampling for Motion Planning,“ in *SoCS*, 2012.
- [39] W. X. M. Y. K. Y. S. Ji., „3D convolutional neural networks for human action recognition,“ in *IEEE TPAMI*, 2013.

- [40] L. B. R. F. L. T. M. P. D. Tran, „Learning Spatiotemporal Features with 3D Convolutional Networks,“ in *International Conference on Computer Vision*, 2015.

Berichtsblatt

1. ISBN oder ISSN Geplant	2. Berichtsart (Schlussbericht oder Veröffentlichung) Schlussbericht
3. Titel Hybride Statistische Lernmethoden für die Embedded-Umsetzung von Sicherheitsfunktionen im Fahrzeug (HySLEUS)	
4. Autor(en) [Name(n), Vorname(n)] Botsch, Michael Chaulwar, Amit	5. Abschlussdatum des Vorhabens 31.01.2018
	6. Veröffentlichungsdatum 31.07.2018
	7. Form der Publikation Abschlussbericht
8. Durchführende Institution(en) (Name, Adresse) i) Technische Hochschule Ingolstadt, Esplanade 10, Ingolstadt 85055. ii) Automotive Safety Technology GmbH, Sachsstraße 16, 85080 Gaimersheim	9. Ber. Nr. Durchführende Institution
	10. Förderkennzeichen 03FH034PX4
	11. Seitenzahl 29
12. Fördernde Institution (Name, Adresse) Bundesministerium für Bildung und Forschung (BMBF) 53170 Bonn	13. Literaturangaben 40
	14. Tabellen 5
	15. Abbildungen 12
16. Zusätzliche Angaben	
17. Vorgelegt bei (Titel, Ort, Datum)	
18. Kurzfassung <p>Statistische Lernmethoden bzw. maschinelle Lernverfahren bieten die Möglichkeit, eine Lösung für komplexe Probleme mit geringen Rechenressourcen zu finden. Sie werden allerdings als „Black-Box“ angesehen, da sie rein datenbasierte Methoden sind. Dies ist der Grund dafür, dass statistische Lernverfahren bisher nicht zu den etablierten Methoden für sicherheitskritische Anwendungen gehören. Hybride statistische Verfahren, bei denen datenbasierte Methoden mit physikalischen Modellen kombiniert werden, eröffnen ganz neue Wege, um die Nachteile rein datenbasierter Lernmethoden zu umgehen und ihre Vorteile auch in der Fahrzeugsicherheit zu nutzen. Das wissenschaftliche Hauptziel des Projekts ist die Erforschung von hybriden statistischen Lernverfahren in der Fahrzeugsicherheit und deren praktische Umsetzung. Dabei werden die zwei Ziele „Sicherheit“ und „geringe Rechenressourcen“ als Bewertungskriterien für die gefundenen Methoden herangezogen.</p> <p>Als primäre Anwendung im Feld der aktiven Fahrzeugsicherheit wird die Aufgabe der sicheren Trajektorienplanung in kritischen Verkehrssituationen betrachtet. Zwei Varianten von analytischen sampling-basierten Algorithmen, „Augmented CL-RRT“ und „Augmented CL-RRT+“, werden für eine sichere Trajektorienplanung in kritischen Verkehrsszenarien mit mehreren statischen und dynamischen Objekten entwickelt und validiert. Die vorhergesagte Schwere der Kollision kann auch für die Trajektorienauswahl berücksichtigt werden, falls keine kollisionsfreie Trajektorie gefunden wird. Die Kombination dieser Algorithmen mit maschinellen Lernmethoden (3D Convolutional Neural Network) führt zu einer deutlich besseren Konvergenz der sampling-basierten Verfahren. Dies wurde bei der Umsetzung der Algorithmen auf drei verschiedenen Mikrocontrollern gezeigt. Die Algorithmen wurden auch durch Realversuche auf der Freiversuchsfläche des Forschungszentrums CARISSMA validiert.</p> <p>Das erforschte Verfahren kann auch auf andere Fragestellungen der Fahrzeugsicherheit oder andere sicherheitskritische Systeme, bei denen die Aufgabe der Absicherung bzw. der interpretierbaren Validierung von maschinellen Lernalgorithmen wichtig ist, angewendet werden.</p>	
19. Schlagwörter Hybride Statistische Lernmethoden, Sichere Trajektorienplanung, Maschinelles Lernen	
20. Verlag	21. Preis

Document Control Sheet

1. ISBN or ISSN Planned	2. type of document (e.g. report, publication) Final Report
3. title Hybride Statistische Lernmethoden für die Embedded-Umsetzung von Sicherheitsfunktionen im Fahrzeug (HySLEUS)	
4. author(s) (family name, first name(s)) Botsch, Michael Chaulwar, Amit	5. end of project 31.01.2018
	6. publication date 31.07.2018
	7. form of publication Final Report
8. performing organization(s) (name, address) i) Technische Hochschule Ingolstadt, Esplanade 10, Ingolstadt 85055. ii) Automotive Safety Technology GmbH, Sachsstraße 16, 85080 Gaimersheim	9. originator's report no.
	10. reference no. 03FH034PX4
	11. no. of pages 29
12. sponsoring agency (name, address) Bundesministerium für Bildung und Forschung (BMBF) 53170 Bonn	13. no. of references 40
	14. no. of tables 5
	15. no. of figures 12
16. supplementary notes	
17. presented at (title, place, date)	
18. abstract Statistical learning and machine learning methods offer the possibility of finding an algorithmic solution for many practical problems with low computational resources. However, they are seen as a "Black-Box" as they are pure data-based methods. This is the reason why statistical learning methods have so far not been used for safety-critical applications. Hybrid statistical learning methods, which are combinations of data-based methods and physical models, open a new way to work around the disadvantages of pure data-based methods while exploiting their advantages for vehicle safety algorithms. The main scientific aim of the project is the exploration of hybrid statistical learning methods for vehicle safety application and their implementation. Hereby, 'safety' and 'low computational resources' are the two evaluation criteria defined for the developed methods. As a primary application in the field of active vehicle safety, the task of safe trajectory planning in critical traffic situations is considered. Two variants of analytical sampling-based algorithms, "Augmented CL-RRT" and "Augmented CL-RRT+", are developed and validated for safe trajectory planning in critical traffic scenarios with several static and dynamic objects. The predicted severity of the collision can also be taken into account for trajectory selection if no collision-free trajectory is found. The combination of these algorithms with machine learning methods (3D Convolutional Neural Network) leads to a significantly better convergence of sampling-based methods. This has been shown by implementing the algorithms on three different microcontrollers. The algorithms were validated in real vehicles on the test track of the research center CARISSMA. The proposed method can also be applied to other vehicle safety applications or other safety critical systems where the topic of an interpretable validation of machine learning algorithms is important.	
19. keywords Hybrid Statistical Learning Methods, Safe Trajectory Planning, Machine Learning	
20. publisher	21. price