

Forschungsprojekt @CITY

Automated Cars and Intelligent Traffic in the City

Schlussbericht

Beitrag des
Zuwendungsempfängers: **AUDI AG**
85045 Ingolstadt

zu den Teilprojekten: **TP1 – Umfelderkennung und Situationsverstehen (ES)**
TP2 – Digitale Karte und Lokalisation (KL)
TP3 – Konzepte und Pilotanwendungen (KP)

Laufzeit: **01.09.2017 – 30.06.2022**

Das diesem Bericht zugrunde liegende Vorhaben wurde mit Mitteln des Bundesministeriums für Wirtschaft und Klimaschutz unter dem Förderkennzeichen **19A17015I** gefördert.

Die Verantwortung für den Inhalt dieser Veröffentlichung liegt beim Autor.

Gefördert durch:



aufgrund eines Beschlusses
des Deutschen Bundestages

Ingolstadt, 21.12.2022



Inhalt

I Kurzdarstellung.....	3
1. Aufgabenstellung.....	4
2. Voraussetzungen	8
3. Planung und Ablauf des Vorhabens	9
4. Wissenschaftliche, technische Ausgangsbasis	13
5. Zusammenarbeit mit anderen Stellen.....	13
II Detaillierte Darstellung.....	15
1. Erzielte Ergebnisse	15
1.1. TP1 – Umfelderkennung und Situationsverstehen (ES)	15
1.1.1. AP1.1 – Spezifikation.....	16
1.1.2. AP1.2 – Erkennen.....	20
1.1.3. AP1.3 – Situationsverstehen.....	38
1.1.4. AP1.4 – Prognose.....	44
1.2. TP2 – Digitale Karte und Lokalisation (KL).....	51
1.2.1. AP2.1 – Digitale Karte.....	51
1.2.2. AP2.2 – Lokalisierung	55
1.2.3. AP2.3 – Plausibilisierung	61
1.3. TP3 – Konzepte und Pilotanwendungen (KP)	65
1.3.1. AP3.1 – Spezifikation und Konzepte.....	66
1.3.2. AP3.2 – Funktionsumsetzung Situationserfassung.....	72
1.3.3. AP3.3 – Funktionsumsetzung Fahrstrategie und Interaktion	75
1.3.4. AP3.4 – Versuchsträgerintegration und Erprobung.....	77
1.4. Literaturverzeichnis	82
2. Anderweitige Fortschritte auf dem Gebiet des Vorhabens	83
3. Veröffentlichungen	83



Öffentlicher Teil

I Kurzdarstellung

@CITY hatte das Ziel, ein neues, automatisiertes Fahrerlebnis für das sichere, stressfreie, effiziente und komfortable Fahren in der Stadt zu generieren. Automatisierte Fahrzeuge und intelligenter Verkehr sind die zentralen Elemente für den Stadtverkehr der Zukunft. Automatisierte Fahrzeuge bieten dem Fahrer in allen Situationen höchstmöglichen Unterstützungsgrad. Die Interaktion zwischen Fahrzeug und Fahrer, aber auch zwischen Fahrzeug und Fußgängern bzw. Radfahrern z.B. an Kreuzungen und Kreisverkehren trägt zu verbessertem Verstehen bei. @CITY automatisiert das Fahren in der Stadt und generiert somit einen Mehrwert nicht nur für den Fahrer, sondern für andere Verkehrsteilnehmer.

Die besonderen Herausforderungen in der Stadt liegen in der Umfelderkennung und -interpretation, vor allem im Situationsverstehen. Aufgrund des komplexen urbanen Verkehrsraums ist gegenüber gut strukturierter Umgebung wie etwa auf Autobahnen eine erheblich präzisere Erkennung erforderlich. Unterschiedlichste Kreuzungen, Kreisverkehre erschweren das Situationsverstehen zusätzlich. Das automatisierte Fahrzeug muss sich in einer hochgenauen Karte präzise lokalisieren. Erst die Kombination von Umfeldinterpretation und Lokalisierung verbunden mit einer breiten Datenbasis ermöglicht ein lernendes und vorausschauendes Situationsverstehen. Zuverlässiges Situationsverstehen wiederum ist die Basis für alle automatisierten Fahrfunktionen für die Stadt.

Das Projekt zielte deswegen auf leistungsfähige, robuste Algorithmen für das Situationsverstehen, auf die Gestaltung der Automation sowie auf die optimale Einbindung des Fahrers. Aufbauend darauf wurden neue automatisierte Fahrfunktionen in der Stadt konzipiert, die dem Fahrer auch in der komplexen urbanen Umgebung mit ihrer hohen Informationsdichte und den sehr kurzen Reaktionszeiten den höchstmöglichen Unterstützungsgrad bieten - auch in Kooperation mit den umgebenden Verkehrsteilnehmern.

Ein übergeordnetes wesentliches Ziel des Projektes war die Gewinnung eines gemeinsamen Verständnisses zum automatisierten Fahren in der Stadt, zu Mindestfunktionalitäten, Systemkonzepten einschließlich benötigter Informationen, Fahrverhaltensweisen und Schnittstellen. Die Partner haben sich hier sehr eng ausgetauscht und sich gegenseitig über die verfolgten algorithmischen Ansätze sowie die dabei gewonnenen Erkenntnisse informiert. Lediglich die konkreten Implementierungsarbeiten wurden partnerspezifisch durchgeführt.

Ein wesentlicher Mehrwert des Projekts @CITY war die Schaffung eines gemeinsamen Verständnisses für automatisiertes Fahren in der Stadt. Das Forschungsprojekt dient als Wegbereiter für gemeinsame, industrielle defacto Standards. Diese wiederum fördern die rasche Umsetzung der im Projekt erarbeiteten



Ergebnisse in der sich an @CITY anschließenden Produktentwicklung sowohl bei den Automobilzulieferern als bei den -herstellern. Frühzeitig mit ausgereiften Produkten auf dem Markt zu sein, ist ein entscheidender Wettbewerbsfaktor für die deutsche Automobilindustrie, v.a. vor dem Hintergrund der auf den Markt für autonomes Fahren drängenden großen Softwareunternehmen wie Alphabet, Microsoft oder Apple.

1. Aufgabenstellung

Ausgehend von der Vielzahl innovativer Assistenz- und Automatisierungssysteme rückt der Weg zum automatisierten Fahren in greifbare Nähe^{1,2}. In den Roadmaps der OEMs werden zukünftige Fahrzeugfunktionen definiert, welche die Fahraufgabe auch in komplexen Situationen automatisiert übernehmen sollen. Um nicht nur auf Autobahnen die Vorteile des automatisierten Fahrens nutzen zu können, sondern automatisiert bis in die Stadt zu fahren, ist eine Reihe von Herausforderungen entlang der gesamten Palette benötigter Technologien (Abbildung 1) zu bewältigen.

Die Fahrzeugumgebung muss extrem robust in allen Use Cases und Szenarien erfasst werden. Für präzise Lokalisierung werden stets aktuelle hochgenaue Karten benötigt. Die Informationen der Umgebungssensorik und der digitalen Karte müssen fusioniert werden. Im Vergleich zum Stand der Technik (Erfassung von Freiräumen sowie von statischen und dynamischen Objekten) ist eine deutlich leistungsfähigere Systemintelligenz erforderlich, die es gestattet, die gesamte Situation zu verstehen, Prognosen über deren weitere Entwicklung zu treffen, und auf dieser Basis geeignete Strategien und Manöver zu entwickeln, sich für das optimale Manöver zu entscheiden und dieses dann autonom umzusetzen.

Dies erfordert im Vergleich zum heutigen Stand Erweiterungen der Systemarchitektur. So müssen Redundanzen bei der Umfelderkennung, aber auch von Steuergeräten und Aktoren vorgesehen werden. Automatisierte Systeme müssen zumindest in elementaren Funktionen (etwa dem Minimum Risk Manöver) fail-operational Funktionalität besitzen. Zuverlässigkeit und Sicherheit, auch der Kommunikation mit anderen Fahrzeugen bzw. der Umwelt, muss garantiert werden.

¹ „Das Auto-Auto, Freiheit ohne Lenkrad: Das selbststeuernde Fahrzeug verändert unser Leben“, Der Spiegel, Nr. 9, 27.02.2016, S. 12-20

² <http://www.sueddeutsche.de/auto/autonomes-fahren-mehr-hirn-fuer-den-autonomen-chauffeur-1.2909300-2>



Abbildung 1: Übersicht über benötigte Technologien für automatisiertes und vernetztes Fahren

Auf die im städtischen Umfeld besonders hohen Herausforderungen wird zur besseren Veranschaulichung in den folgenden Abschnitten näher eingegangen.

Herausforderung: Umfelderkennung und Situationsverstehen

Automatisiertes Fahren erfordert sicheres Situationsverstehen. Voraussetzungen hierfür sind z.B. das Verständnis von Topologie, Verkehrsführung, Intentionen, Verkehrsregeln, Verhaltensmustern sowie Wechselwirkungen zwischen Verkehrsteilnehmern.

Die Entwicklungen für teil- und hochautomatisierte Fahrfunktionen hatten bisher i.d.R. ihren Fokus auf Autobahnen und autobahnähnlichen Straßen mit baulich getrennten Richtungsfahrbahnen. In diesen Szenarien ist die Komplexität und Anzahl der typischen Fahrmanöver noch gering. Die Wechselwirkung zwischen den Verkehrsteilnehmern kann in Form von regelbasierten Verhaltensstrategien häufig explizit abgebildet werden. Zur sensorischen Erfassung der Fahrbahninfrastruktur und anderer Verkehrsteilnehmer, z.B. durch Kamera-, Radar- und Lidarsysteme, ist für Autobahnszenarien inzwischen ein technisch fortgeschrittener Stand erreicht. Im Gegensatz dazu hat die sensorische Umfelderkennung für automatisiertes Fahren im urbanen Umfeld noch große Herausforderungen zu meistern.

Abbildung 2 zeigt ein Beispiel einer urbanen Kreuzung. Obwohl die Kreuzung recht übersichtlich aussieht, verdeutlicht das Bild bereits die Vielfalt etwa an Verkehrsteilnehmern, die Infrastruktur mit Ampeln, Richtungspfeilen, parkende Fahrzeuge. Im Vergleich zu gut strukturierter Umgebung von Autobahnen sind die einzuhaltenden Verkehrsregeln erheblich komplexer.



Abbildung 2: Beispiel einer urbanen Kreuzung³

Die Variabilität von häufig historisch gewachsenen Verkehrsführungen ist im städtischen Bereich sehr groß und der Zustand der Verkehrsinfrastruktur ist nicht immer gut. Zudem ist die Diversität der Verkehrsteilnehmer im Vergleich zur Autobahn sehr groß und die verfolgten Ziele und Intentionen der Verkehrsteilnehmer sind mannigfaltig. Aus diesen Gründen weist auch deren Verhalten ein großes Spektrum auf.

Um ein vorausschauendes und kooperatives Fahrverhalten des automatisierten Fahrzeugs im Zusammenspiel mit anderen Verkehrsteilnehmern - etwa nicht automatisierten Fahrzeugen, Fußgängern, Radfahrern - generieren zu können, muss das automatisierte Fahrzeug in der Lage sein, das Verhalten der anderen Verkehrsteilnehmer für die nächsten Sekunden vorherzusagen und die Wechselwirkungen des eigenen Handelns auf die anderen Verkehrsteilnehmer und umgekehrt zu bewerten. Diese Prognose erfordert es, den Situationskontext mit entsprechenden Randbedingungen im Vergleich zum Stand der Technik detaillierter zu erfassen.

So muss das automatisierte Fahrzeug die Verkehrsführung erkennen, was insbesondere in Kreuzungsszenarien aktuell sensorisch nicht überall lösbar ist, weshalb die Ergänzung mit präziser digitaler Karteninformation notwendig wird. Das System muss auf Basis der Verkehrsregeln und insbesondere der gültigen Vorfahrtsregelungen mit anderen Verkehrsteilnehmern interagieren. In der Stadt reicht dabei beim Rangieren auf engem Raum häufig der Detaillierungsgrad der aktuellen Objektmodelle bzw. die Modellierung des statischen Umfelds noch nicht aus.

³ <http://www.autobahnatlas-online.de/Bildergalerie/A46-002KreuzungEmilienpl.jpg>



Insbesondere inhomogene Fahrbahnoberflächen und Begrenzungsverläufe erschweren die Bestimmung des befahrbaren Fahrkorridors rein aus Sensordaten. Auch hier soll die Umfelderkennung mittels plausibilisierter digitaler Karteninformation ergänzt werden.

Selbst bei Regelverstößen, wie z.B. Parken in zweiter Reihe, muss das Fahrzeug ein risikominimierendes Verhalten an den Tag legen. Es muss mit Verdeckungen und temporär fehlendem Wissen bezüglich eigentlich relevanter Information umgehen können und dennoch ein sicheres kooperatives Fahren ermöglichen. Die Abbildung der situativ relevanten Information und dazu das Verständnis des Systems dafür, dass relevante Information, z.B. in einer Kreuzungssituation aufgrund von Verdeckung, fehlt, ist dabei sowohl eine Herausforderung an die Repräsentation im System als auch an die nachgelagerte funktionale Verhaltensstrategie.

Herausforderung: Präzise digitale Karte und Lokalisation

Selbstfahrende Autos werden ihre Position in der Verkehrsumgebung bestimmen müssen. Autonome Fahrzeuge können mittels digitaler Umgebungskarten a priori Informationen der realen Umgebung in die Umfelderkennung einbinden. Diese ist in Kooperation mit Fahrzeugsensoren der Schlüssel zu zuverlässigen selbstfahrenden Autos. Die Plausibilität der digitalen Umgebungskarten muss jederzeit anhand der Daten der fahrzeugeigenen Sensoren bewertet werden. Für hoch- und vollautomatisiertes Fahren ist die Notwendigkeit der Integration von „high-definition“ Karten substanziell in Bezug auf die Herausforderungen der Fahrszenarien im urbanen Bereich mit multiplen Verkehrselementen.

Die reale Welt ist ständiger Veränderung unterworfen. Autonom fahrende Autos werden deshalb Anforderungen an digitale Karten stellen, die von heutigen Karten noch nicht erfüllt werden. Solche Karten werden sich in Bezug auf viele wichtige Eigenschaften von heutigen Karten unterscheiden, welche hauptsächlich für die korrekte Navigation gedacht sind. Automatisiertes Fahren erfordert Karten, welche z. B. die Lage eines Bordsteins mit der Genauigkeit von wenigen Zentimetern angeben können. Solche „high-definition“ Karten können als ein weiterer Sensor (zusätzlich zu den im Fahrzeug integrierten Sensoren zur Umfelderkennung) betrachtet werden, welcher die Daten mit einer praktisch uneingeschränkten Reichweite liefern kann. Abschließend kann die Karte als ein „natürliches“ Format zur Speicherung aller eingehenden Daten betrachtet werden, welche von den Umfelderkennungssensoren des Fahrzeugs oder aus der Cloud (Back-End Ansatz) geliefert werden. Durch dieses Format stehen alle Umgebungsdaten den Algorithmen des selbstfahrenden Fahrzeugs zur Verfügung – es könnte somit das Interface zwischen realer Welt und autonom fahrendem Auto sein. Eine wesentliche Herausforderung liegt darin, die Gültigkeit und Qualität der Daten vor der Nutzung mit ausreichender Genauigkeit zu quantifizieren.

Herausforderung: Konzepte

Urbane Szenarien stellen nicht nur große Herausforderungen an eine technische Lösung (von Hardware, über Algorithmik bis hin zur finalen Software) dar, sondern auch die Spezifikationen und Konzepte für all diese Szenarien sind neu zu



überdenken, um eine entsprechende Basis für die weiteren Arbeiten im Projekt zu bilden und weitere über dieses Projekt hinausgehende Forschungen zu erlauben. Ein wichtiges Element hierfür sind formale Beschreibungen von Szenarien, die als Abprungbasis sowohl für den Entwicklungs- als auch für den Validierungs-/ Verifikationspfad dienen können.

Ein wichtiger Aspekt hierbei ist, die gewonnenen Ergebnisse allgemein zugänglich zu machen und diese idealerweise als Basis für eine Standardisierung heranzuziehen.

Herausforderung: Urbane Straße, Knotenpunkte und schwächere Verkehrsteilnehmer

Um eine automatisierte Fahrt durch eine Stadt zu ermöglichen, sind noch weitere Herausforderungen wissenschaftlich und technisch zu meistern. Dies sind neben Entscheidungs- und Planungsaufgaben auch die Fragestellung, wie Informationen in einem so komplexen Umfeld am besten dem Fahrer übermittelt werden können, so dass er diese auch aufnehmen kann.

Es wurde hierzu ein weiteres Förderprojekt *@CITY-AF (@CITY-Automatisierte Fahrfunktionen)* aufgesetzt, an dem sich die AUDI AG ebenfalls beteiligte. Ergebnisse zu diesen Sachverhalten können im Abschlussbericht zu *@CITY-AF* der AUDI AG nachgelesen werden.

2. Voraussetzungen

Der Stellenwert von Fahrerassistenzsystemen im Automobil steigt ständig. Speziell automatische Fahrfunktionen der SAE-Automationslevel 3 und 4 wird ein großer Markt vorhergesagt. Dies wird durch rasante Fortschritte im Bereich künstlicher Intelligenz getrieben. Vor allem im Bereich der Umfeldwahrnehmung und der Situationsinterpretation zeigt diese neue Technologie ihre Vorzüge.

Als Premiumhersteller sieht die AUDI AG großes Potential in diesem Sektor. Die Erforschung und Entwicklung von Fahrerassistenzsystemen und automatisierter Fahrfunktionen hat für Audi daher große strategische Bedeutung. Es wurden Voraussetzungen geschaffen, neue Technologien im Bereich der Umfeldsensoren oder der künstlichen Intelligenz für neue Assistenzsysteme bzw. automatische Fahrfunktionen zu nutzen.

Mit der Einführung des ersten ACC (Adaptive Cruise Control) 2003 im A8 der dritten Generation war Audi einer der ersten Fahrzeughersteller der Fahrerassistenzsysteme den Kunden angeboten hat. Mit dem audi side assist folgte im Jahr 2005 ein weiteres Assistenzsystem, welches sein Wirkungsfeld in der Beeinflussung der Querdynamik hat. Mit der Einführung des Stauassistenten (SAE Level 2) im Q7 der zweiten Generation konnte erstmals auch auf Ergebnisse aus dem Förderprojekt *INVENT*, Teilprojekt *Stauassistent* zurückgegriffen werden. Diese Systeme der Längs- und Querverführung werden kontinuierlich weiterentwickelt. Es ist somit gewährleistet, dass die im Rahmen von *@CITY* erzielten Forschungsergebnisse zeitnah Einzug in vorhandene Seriensysteme finden werden.



Neben der kontinuierlichen Weiterentwicklung von automatisierten Fahrfunktionen ist die Einführung derartiger Systeme auch in der Mittel- und Kompaktklasse erklärtes Ziel der AUDI AG. Somit ist die Basis vorhanden, dass Ergebnisse aus der Forschungsinitiative @CITY über die gesamte Modellpalette Anwendung finden.

3. Planung und Ablauf des Vorhabens

Bei der Planung des Vorhabens konnte seitens der AUDI AG auf die Erfahrungen aus Vorgängerprojekten wie *INVENT (Intelligenter Verkehr und nutzergerechte Technik)*, *AKTIV (Adaptive und kooperative Technologien für den intelligenten Verkehr)* oder *UR:BAN (Urbaner Raum: Benutzergerechte Assistenzsysteme und Netzmanagement)* zurückgegriffen werden. Die Planung konnte daher – auch aufgrund der guten Kooperation mit den @CITY-Projektpartnern in der Vorbereitungsphase – sehr zügig abgeschlossen werden. Die angenommenen Kosten für Eigen- und Fremdleistung erwiesen sich als sehr realistisch. Der Projektfortschritt wurde zwar durch die Corona-Pandemie gestört, durch eine kostenneutrale Verlängerung des Projekts bis Ende Juni 2022 konnte dies allerdings ausgeglichen werden.

Die Planung des Vorhabens (@CITY) sah eine Laufzeit vom 01.09.2017 – 31.08.2021 vor. Aufgrund der Corona-Pandemie wurde das Projekt bis 30.06.2022 kostenneutral verlängert. Innerhalb dieser Laufzeit konnten von allen Partnern die geplanten Ergebnisse erzielt werden.

Für die drei Teilprojekte des Förderprojekts @CITY wurde über die Projektlaufzeit eine zeitliche Abfolge einzelner Meilensteine definiert. Im Folgenden ist der Zeitplan für @CITY exemplarisch aufgeführt (siehe

Abbildung 3):

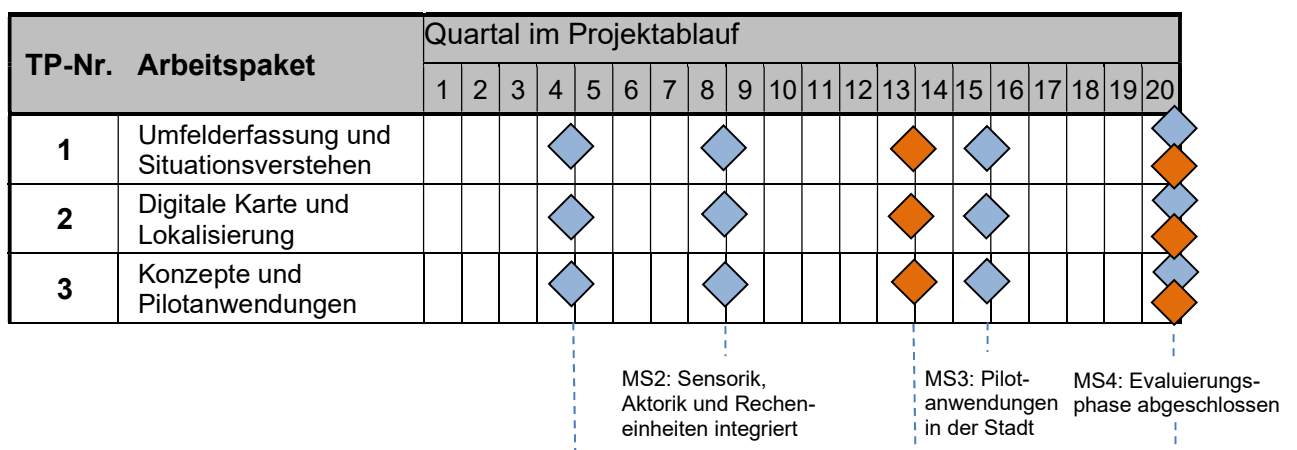


Abbildung 3: Projektplan für @CITY

Die erreichten Projektergebnisse wurden einer breiten Öffentlichkeit anlässlich der Halbzeitpräsentation (26. und 27. November 2020) vorgestellt. Aufgrund der Corona-Pandemie konnte diese Veranstaltung nicht in Präsenz durchgeführt werden, sondern es wurde auf ein Online-Format ausgewichen, welches sich aber ebenso bewährt hat.

Seitens Audi wurde bei der Halbzeitpräsentation das erste von zwei für @CITY aufgebaute Erprobungsfahrzeug vorgestellt. Hierzu wurde ein Video über das Erprobungsfahrzeug (siehe Abbildung 4) erstellt, welches die technischen Modifikationen (Zusatzsensorik, Modifikationen an den Fahrwerksaktoren, zusätzliche Rechner Technik etc.) am Fahrzeug im Detail illustriert. Die Inbetriebnahme und Integration der Funktionssoftware im Erprobungsfahrzeug schloss sich unmittelbar an die Halbzeitpräsentation an.



Abbildung 4: Erprobungsfahrzeug der AUDI AG

Nach vielen Testkilometern und einigen Testtagen auf dem Gelände des Aldenhoven Test Centers (ATC), welche dankenswerter Weise vom Projektbüro mit der Streckenleitung des ATC abgestimmt wurden, fand am 22. und 23. Juni 2022 zusammen mit dem Schwesterprojekt @CITY-AF die Abschlusspräsentation eben auf

diesem Testgelände in Aldenhoven statt. Seitens Audi wurden bei dieser Veranstaltung Ergebnisse zu den Teilprojekte TP1, TP2 und TP3 präsentiert.

Hierzu wurde auf dem Streckennetz des ATC eine durchgängige Route definiert (siehe Abbildung 5, blaue Markierung), entlang derer typische urbane Szenarien wie Kreuzungsszenarien mit und ohne Ampelregelung, Kreisverkehr, Engstellen usw. verortet waren. Aus TP1 konnte die Wahrnehmung von stationärer Infrastruktur wie dem Straßennetz oder von dynamischen Objekten wie anderen Fahrzeugen gezeigt werden. Durch die in TP2 entwickelten Lokalisierungsalgorithmen konnte das Zusammenspiel mit einer digitalen Karte demonstriert werden, welches für die Ortsbestimmung eines automatisiert fahrenden Fahrzeugs elementar ist, um seine Position in der Welt zu kennen. Last but not least wurde im Rahmen des TP3 ein dynamisches Engstellenszenario vorgestellt. Konkret handelt es sich um ein Szenario an einer Bushaltestelle (roter Kreis in Abbildung 5). Ein automatisiert fahrendes Fahrzeug (in diesem Fall das Audi-Erprobungsfahrzeug) nähert sich einer Bushaltestelle. Ein Bus ist im Begriff die Bushaltestelle zu verlassen. Je nach Position des Eigenfahrzeugs relativ zum Bus wird dem ausfahrenden Bus, der dies durch Blinkzeichen ankündigt, die Vorfahrt gewährt, oder bei zu geringem Relativabstand zum Bus, die Engstelle schnell passiert (siehe Abbildung 6).



Abbildung 5: Demo-Route auf dem ATC im Rahmen der @CITY-Abschlusspräsentation



Abbildung 6: Engstellenszenario – Bushaltestelle

Trotz der heißen Temperaturen an den Präsentationstagen konnte die Abschlusspräsentation seitens Audi mit vollem Erfolg durchgeführt werden und die „Audi-Mannschaft“ war nach der Veranstaltung sichtlich erleichtert (siehe Abbildung 7).



Abbildung 7: Mannschaft der AUDI AG mit den beiden @CITY-Erprobungsfahrzeugen am Ende der Abschlusspräsentation in Aldenhoven



In diesem Bericht sind nur die 3 Teilprojekte aus @CITY aufgeführt. Bei der Abschlusspräsentation wurde allerdings eine vollständige automatisiert Fahrt auf dem Prüfgelände gezeigt. Die fehlenden Szenarien wie Kreuzungen, Kreisverkehre etc. waren Inhalt des Schwesterprojekts @CITY-AF. Zur Vervollständigung eines Gesamtbildes sei daher auf den Abschlussbericht des Förderprojekts @CITY-AF verwiesen.

4. Wissenschaftliche, technische Ausgangsbasis

Die AUDI AG verfügt über eine lange Historie im Bereich von Förderprojekten und Wissenschaftskooperationen mit Hochschulen. So war die AUDI AG an Förderprojekten wie *INVENT*, *AKTIV* und *UR:BAN* aber auch an *PEGASUS* und *Ko-HAF* beteiligt. Es konnten somit Erfahrungen im Bereich der Durchführung und Zusammenarbeit in Förderprojekten gesammelt werden. Dieses Wissen ist die Basis für die Durchführung des Förderprojekts @CITY. Daneben verfolgt die AUDI AG im wissenschaftlichen Umfeld einen engen Austausch mit sogenannten Kooperations-Universitäten. Mit diesen wurden die Rahmenbedingungen für Drittmittelprojekt einheitlich geregelt, so dass das Aufphasen einzelner Projekte keinen großen administrativen Aufwand mehr bedeutet. Auch dieser Umstand kam in @CITY zum Tragen, da ein Themenschwerpunkt als Drittmittelprojekt an die Friedrich-Alexander-Universität Erlangen vergeben werden konnte, wo die Bearbeitung im Rahmen einer Promotion durchgeführt wurde.


Daneben verfügt die AUDI AG auch über entsprechende technische Voraussetzungen, um ein Förderprojekt im Bereich automatisierten Fahren durchführen zu können. Ein entscheidender Aspekt dabei ist, dass Audi bereits über die gesamte Modellpalette Fahrerassistenzsysteme anbietet. Somit ist zum einen die technische Basis geschaffen, diese Systeme sukzessiv zu erweitern und somit die Ergebnisse aus Förderprojekten zeitnah in ein Serienprodukt einfließen zu lassen. Zum anderen sind Fahrzeuge mit Assistenzausstattung eine gute Basis für den Aufbau von Erprobungsfahrzeugen. In der nun vierten Generation von Erprobungsfahrzeugen für das automatisierte Fahren kann die AUDI AG auch auf einen stetig wachsenden Erfahrungsschatz zurückgreifen, der wiederum im Förderprojekt @CITY genutzt wurde.

5. Zusammenarbeit mit anderen Stellen

Die Aktivitäten anderer parallel zum Vorhaben laufenden Förderprojekte wurden während der Projektlaufzeit ständig verfolgt. Es ergaben sich dabei jedoch keine Ansatzpunkte für eine konkrete Zusammenarbeit.

Innerhalb des Volkswagen-Konzerns erfolgte während der gesamten Laufzeit des Vorhabens ein ständiger Erfahrungsaustausch zwischen den beteiligten Marken AUDI AG, Audi Electronics Venture GmbH und Volkswagen Konzernforschung.

Anders als bei Vorgängerprojekten wurde die Zusammenarbeit mit Hochschul- und Forschungsinstituten aufgrund der Corona-Pandemie nicht so intensiv gepflegt. Es



wurden über die gesamte Projektlaufzeit Kooperationen mit Hochschul- und Forschungsinstituten gepflegt:

- Friedrich-Alexander-Universität Erlangen, Lehrstuhl für Informationstechnik
- Universität Passau, Forwiss-Institut

II Detaillierte Darstellung

1. Erzielte Ergebnisse

Die AUDI AG beteiligte sich im Rahmen der Forschungsinitiative @CITY an den drei Teilprojekten *Umfelderfassung und Situationsverstehen (ES)*, *Digitale Karte und Lokalisation (KL)* und *Konzepte und Pilotanwendungen (KP)*. Im Folgenden werden die Vorgehensweise und die erzielten Ergebnisse im Detail dargestellt.

1.1. TP1 – Umfelderfassung und Situationsverstehen (ES)

Für das Teilprojekt TP1 *Umfelderfassung und Situationsverstehen (ES)* hatte AUDI die Teilprojektleitung übernommen.

Das Teilprojekt hatte nachfolgende Projektstruktur:

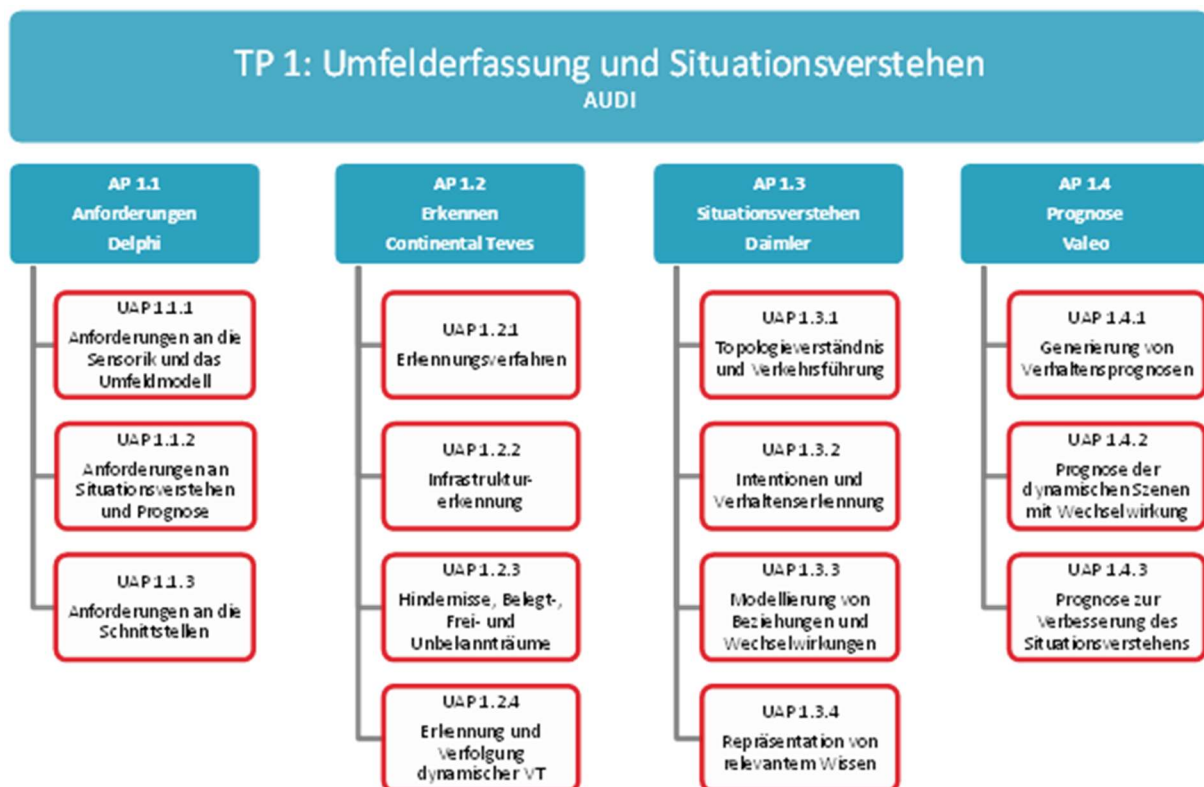


Abbildung 8: Struktur von TP1 „Umfelderfassung und Situationsverstehen“



1.1.1. AP1.1 – Spezifikation

Entsprechend der Vorhabensbeschreibung und Projektstruktur wurden zunächst für das urbane Fahren relevante Szenarien identifiziert und eine adäquate Methodik und Vorgehensweise zur Beschreibung der situativen Abläufe gemeinsam erarbeitet und festgelegt. Die Nomenklatur zur formal vollständigen Beschreibung von Szenarien und ein Glossar für die Begriffe wurde dabei in TP3 in Zusammenarbeit mit TP1 und TP2 erarbeitet.

Auf Basis der Ablaufbeschreibungen wurden dann generische Anforderungen an die Sensorik und Erkennungsmodule anhand der in den situativen Abläufen beim Durchfahren und Interagieren mit der Infrastruktur (z.B. Vorfahrtsregelung durch Vorfahrt-Gewähren-Schild, Stopp-Schild oder Lichtsignalanlage (LSA)) und anderen Verkehrsteilnehmern relevanten Informationen abgeleitet. Die Beschreibung der Anforderungen erfolgte deshalb in einem generischen Format, so dass die verschiedenen Projektpartner zur Erfüllung der Anforderungen an die Erkennung jeweils mit ihren partnerspezifischen Sensorkonfigurationen und -technologien Lösungen erarbeiten konnten.

Die Ableitung von Anforderungen hat sich deshalb an folgenden Leitplanken orientiert:

- technologie-unabhängige generische Anforderungen an Sensorik, d.h. Objekttypbezogene Reichweiten, Sichtbereiche und Genauigkeiten
- Methodenunabhängige Anforderungen an relevante Informationen als Output des Moduls Situationsverstehen (Bedeutungen, Aussagen, Beziehungen) für die Schnittstelle hin zu den Planungsmodulen auf taktischer oder strategischer Ebene
- Methodenunabhängige Anforderungen an relevante Informationen, welche als Output aus dem Modul Prognose als Input für das Modul Situationsverstehen geliefert werden sollen.

Im Rahmen des Unterarbeitspakets UAP1.1.1 „Anforderungen an Sensorik und das Umfeldmodell“ hat Audi an der Erstellung von folgenden Ablaufdiagrammen und Ableitung von Anforderungen an die Sensorik mitgewirkt:

- a. Fahren auf Verbindungsstrecken mit statischer Engstelle bzw. mit dynamische Engstelle z.B. Bus an Bushaltestelle
- b. Durchfahren eines Kreisverkehrs
- c. Durchfahren von Kreuzungen

Die nachfolgende Abbildung 9 zeigt beispielhaft auf oberster Beschreibungsebene den Ablauf eines Ausweichmanövers an einer statischen Engstelle z.B. durch ein in der zweiten Reihe parkendes Fahrzeug. Für die in dem Ablaufdiagramm enthalten Blöcke gibt es jeweils weitere Detaillierungen.

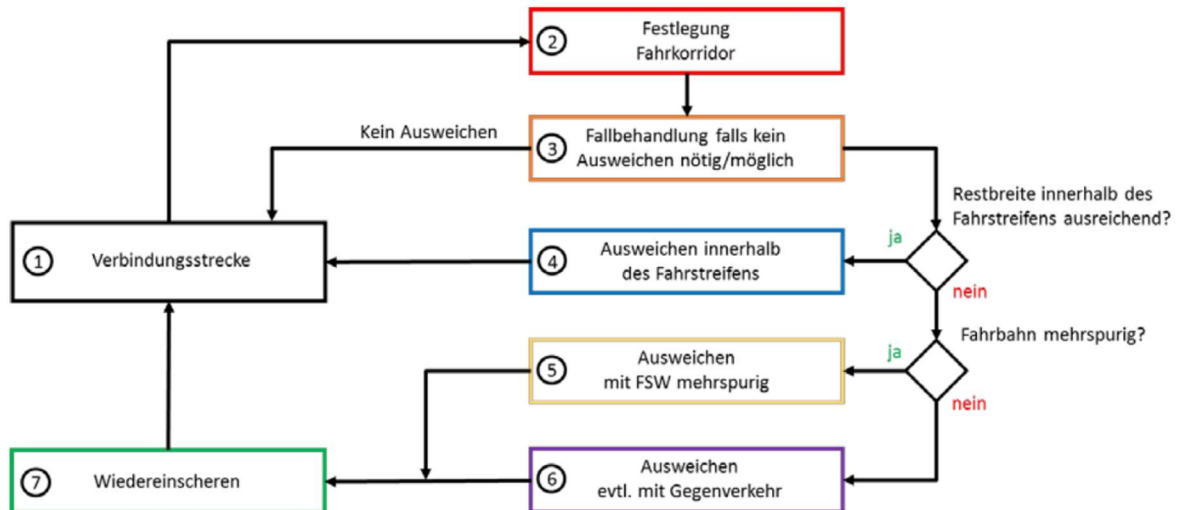


Abbildung 9: Übersicht des Ablaufs des Szenarios „Fahren auf Verbindungsstrecke mit Engstelle“

Anhand typischer Konstellationen z.B. an einer solchen statischen Engstelle mit Gegenverkehr wurden die notwendigen Erkennungsreichweiten der Sensorik mit und ohne notwendige Kooperation des Gegenverkehrs bei verschiedenen Geschwindigkeiten ermittelt. Diese Ergebnisse können im Meilensteinbericht MS1 zum TP1 nachgelesen werden. Die nachfolgende Abbildung 10 zeigt die relevanten Variablen zur Berechnung der dynamischen Größen und Fahrstrecken, um daraus die Anforderungen an die notwendigen Erkennungsreichweiten und Sichtbereiche von Sensoren abzuleiten. Die Details zur Berechnung finden sich ebenfalls im TP1-Meilensteinbericht.

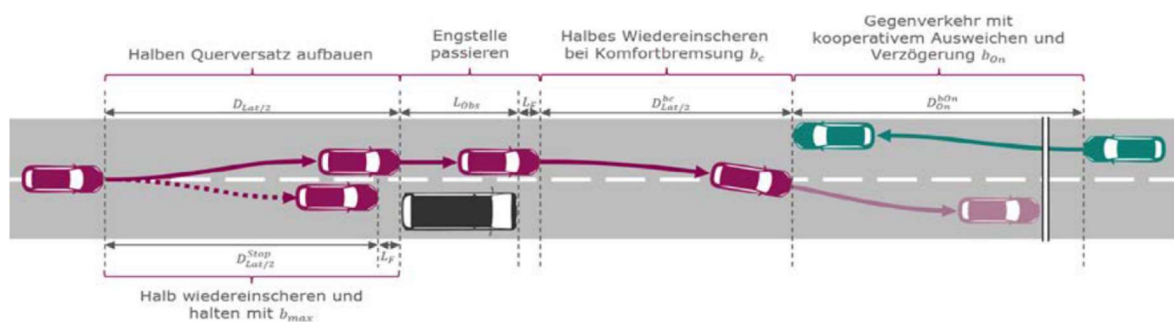


Abbildung 10: Phasen des Ausweichmanövers mit kooperativem Gegenverkehr

Ein weiteres Beispiel zur Abschätzung der notwendigen Sensorsichtbereiche und Reichweite für die Erkennung von Objekten bei Annäherung und Einfahrt in einen Kreisverkehr findet sich in den nachfolgenden beiden Abbildungen.

Hierbei wurden die Abschätzungen für notwendige Sichtbereiche in Abhängigkeit vom Kreisradius und vom Anschlussstellenwinkel der Kreiszufahrt für das Anhalten am Kreisverkehr bzw. Anfahren am Kreisverkehr betrachtet und die Analyse mittels graphischer Darstellung in Python umgesetzt.

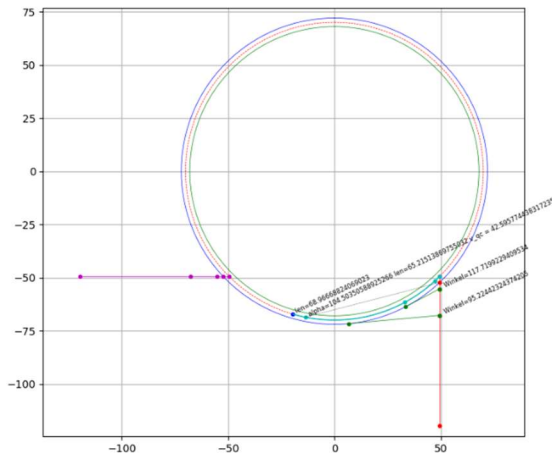


Abbildung 11: Großer Kreisler R=70m und 45° Zufahrt

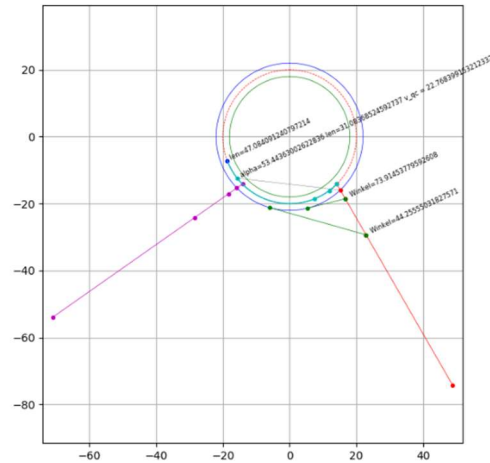


Abbildung 12: Kreisler R=20m und 75°

Ferner wurden die von 3DMapping erstellten Karten für unsere Pilotstrecke in Ingolstadt in eine Simulation eingelesen, um das Sensorset vor der Integration in den Versuchsträger simulativ zu validieren und anhand realer Geometrien visualisieren zu können. Die nachfolgende Abbildung 13 zeigt für einen realen Kreisverkehr unserer Pilotstrecke in Ingolstadt, was in den Kameras zu sehen wäre, wenn das Fahrzeug an einer der Haltelinien stehen würde. Eine Darstellung unseres Versuchsträgers mit der verbauten Sensorik ist in Abbildung 4 zu sehen.




Abbildung 13: Simulation der Videosichtbereiche für Ego an Zufahrt eines Kreisverkehrs auf Pilotstrecke

Im Unterarbeitspaket UAP 1.1.2 „Anforderungen an Situationsverstehen und Prognose“ wurden notwendige funktionale Blöcke und Aufgaben des Situationsverstehens und der Prognose definiert. Beispielsweise laufen im Situationsverstehen die Informationen aus der Topologie des Straßennetzes aus der digitalen Karte mit Vorfahrtsregelung, die Zuordnung von Objekten zu Fahrpfaden, das Wissen über Hindernisse, Verdeckungsgebiete und ferner z.B. Geschwindigkeitslimits und objekttypische gefahrene Geschwindigkeiten für bestimmte Krümmungsverläufe für komfortable Querbeschleunigungen zusammen. Das Situationsverstehen werden dann Prognosen mit den Methoden, welche im AP 1.4 Prognose entwickelt wurden, entlang möglicher Pfade mit den objekttypischen Geschwindigkeiten und unter Berücksichtigung einfacher Interaktionen über die zukünftigen Positionen der Verkehrsteilnehmer errechnet, so dass der daran anschließende Planer auf Basis der aktuellen und vorhergesagten Szenerie eine

möglichst adäquate Ego-Trajektorie durch Optimierung in Raum und Zeit errechnen kann. Die Beschreibung der Aufgaben der funktionalen Blöcke ist ebenfalls im Meilensteinbericht MS1 nachzulesen.

Im UAP 1.1.3 „Anforderungen an die Schnittstellen“ wurde für ein gemeinsames Verständnis und eine gemeinsame „Sprache“ eine mögliche funktionale Architektur mit notwendigen funktionalen Blöcke (Abbildung 14) definiert, wodurch es möglich wurde partnerübergreifend die an den Schnittstellen relevanten Inhalte und Anforderungen an deren Erkennung oder deren Aufbereitung z.B. im Situationsverstehen zu beschreiben.

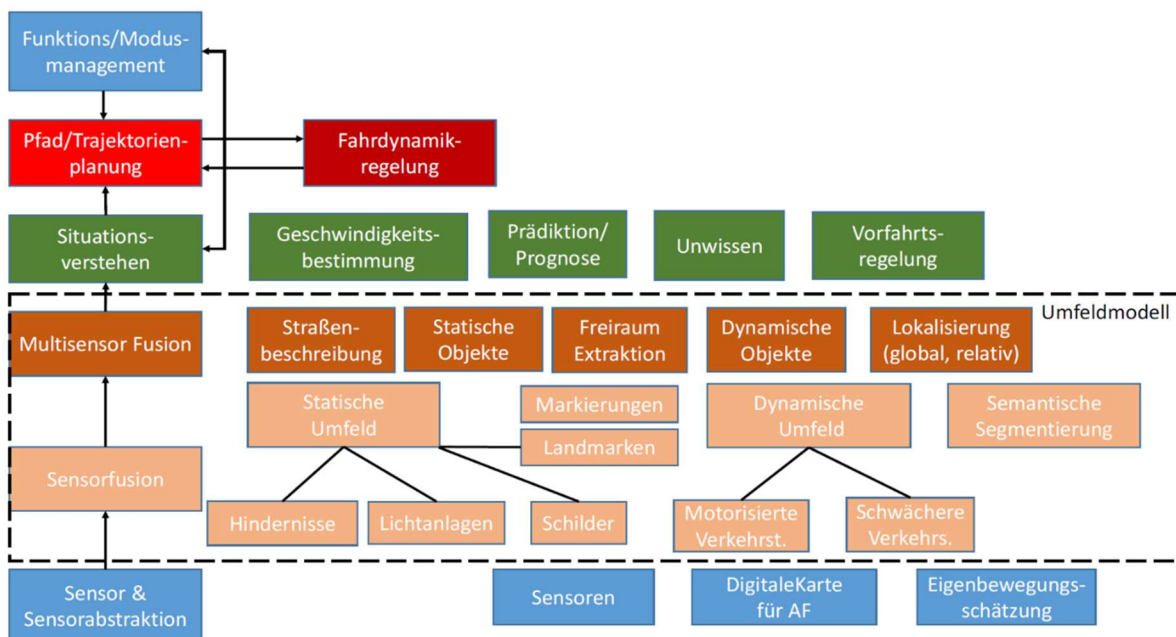


Abbildung 14: Funktionale Architektur der Umfelderkennung

Das gemeinsame Ergebnis aller Partner des AP1 „Spezifikation“ war der TP1-Meilensteinbericht1:



atCITY MS-1 TP-1.pdf

1.1.2. AP1.2 – Erkennen

1.1.2.1 UAP1.2.1 – Erkennungsverfahren

Zur Detektion und Klassifikation von Linien, Pflastergrenzen, Bordsteinen und Asphaltgrenzen für die Fahrbahninfrastrukturerkennung und zur Erkennung und Klassifikation des Objekttyps wurden bei Audi im Projekt @CITY maschinelle Lernverfahren insbesondere CNNs zur Segmentierung und Klassifikation von Bildinhalten eingesetzt. Mittels Optimierungen war es möglich diese ML-basierten semantische Klassifikation von Videobildern in ihrer Performance- und Laufzeit so zu verbessern, dass es möglich war auf mehreren Kameras die Algorithmen im Fahrzeug laufen zu lassen, so dass insbesondere der Frontbereich durch die Kamerasichtbereiche abgedeckt war. Die gleichzeitige Inferenz der semantischen Segmentierung auf aktuell 5 Kameras für die 360° Erfassung hatte noch zu hohe Anforderungen an den Datendurchsatz und die Rechenleistung der Grafikkarten und konnte bis zum Ende des Projekts nicht mit voller Bildwiederholrate dargestellt werden. In Abbildung 15 sind Videobilder der fünf auf dem Dach angebrachten Videokameras zu sehen, welche insbesondere an Kreuzungen und Kreisverkehren ein weites Sichtfeld für den Abbiege- oder Einfädelvorgang ermöglichen. Zusätzlich sind noch unten links und unten rechts beispielhaft Videobilder der seitlichen Kameras zu sehen, welche der Überwachung des seitlichen Bereichs bezüglich überholender Fahrzeuge oder Radfahrer und Fußgänger beim Rechtsabbiegen dienen.



Abbildung 15: Videobilder am Kreisverkehr Aldenhoven

In Abbildung 16 ist das Ergebnis der semantischen Segmentierung mittels tiefer neuronaler Netze auf den 5 Kameras mit etwas gedrosselter Bildwiederholrate zu sehen. Aufgrund der hohen Anforderungen an die Rechenleistung wurde der

Auswertebereich auf den für die Objekterkennung relevanten Bereich beschränkt. In den Bildern sind die unterschiedlichen semantischen Klassen farblich kodiert. Z.B. Fahrzeuge in Rot, Linien in Dunkelblau, Leitplanken in Cyan, Natur in Grün, Asphalt in Grau. Auch wenn die semantische Klassifikation im Bild häufig schon sehr gut funktioniert, kann es dennoch zu Fehlern bezüglich der wahrscheinlichsten Klasse je Pixel kommen, d.h. eventuell ist dann die zweite oder drittwahrscheinlichste Klasse die Richtige. Es ist dann die Aufgabe des Objekttrackings oder des Fahrstreifentrackers in der Sensordatenassoziation oder durch entsprechende zeitliche Filterung aufeinanderfolgender Messungen und Fusion mit weiteren Sensoren wie z.B. Radar oder Laser das Umfeldmodell robust zu gestalten.




Abbildung 16: Beispiel für semantische Klassifikation der Videobilder

1.1.2.2 UAP1.2.2 – Infrastrukturerkennung

Um die Informationen digitaler Karten nutzen zu können, war es notwendig die relative Lage des Ego-Fahrzeugs gegenüber der digitalen Karte zu bestimmen. Diesen Vorgang bezeichnen wir als Lokalisierung und er ist Teil des TP2. Als Basis für die Lokalisierung werden Landmarken benötigt, welche sowohl sensorisch erkannt werden können und deren Lagen hochgenau in der digitalen Karte repräsentiert sind. Zur Erkennung dieser Landmarken wurden z.B. ein Laser-basierter Pfostenerkennung, siehe Abbildung 17, für die Nutzung in urbanen Szenarien, wie z.B. im Kreisverkehr, weiterentwickelt. Ferner wurde ein Detektor für Richtungspfeile und Linienstücke angebunden (Siehe Abbildung 18).



Abbildung 17: Lidarbasierte Landmarkenerkennung insbesondere Pfeile (Straßenlaternen, Leitpfosten Schilderpfosten) zur Nutzung für die Lokalisierung, welche hier ins Videobild zur Kontrolle der Erkennungsleistung rückprojiziert wurden




Abbildung 18: Videobasierte Erkennung von Richtungspfeilen und kurzen Liniensegmenten als Landmarken für eine Lokalisierung gegenüber einer digitalen Karte und zur statischen Umfeldfusion

Für die Fahrstreifenerkennung wurden die mittels ML semantisch als Fahrstreifengrenzen klassifizierten Pixel mittels invers perspektivischer Transformation in die lokale Fahrbahnebene transformiert und dort in Eigenschaftsbelegungsgittern akkumuliert. Dies hat den Vorteil, dass auch im dichten Verkehr bereits gesehene Begrenzungsverläufe für die Fahrstreifenerkennung nutzbar bleiben, auch wenn diese temporär z.B. durch andere Fahrzeuge wieder verdeckt werden.

Für den Kreisverkehr hat sich ferner gezeigt, dass die für eine Akkumulation grundlegende relative Eigenbewegungsschätzung, wie in Abbildung 19 zu sehen, bereits eine sehr gute Qualität zur Kompensation der Eigenbewegung bei der Akkumulation liefert.




Abbildung 19: Eigenbewegungsschätzung (rot) im Vergleich zur Referenz mit iTrace IMU (grün). Die Abweichung liegt im kleinen dm-Bereich.

Abbildung 20 zeigt die er Akkumulation verschieden Fahrstreifenbegrenzungen in den jeweiligen Eigenschaftsbelegungsgittern auf Basis der semantischen Information.




Abbildung 20: Akkumulation der semantischen Information an einem Kreisverkehr in Eigenschaftsbelegungsgittern mittels invers-perspektivischem Mapping der semantischen Pixel

Im Speziellen gab es im Projekt @CITY einige Weiterentwicklungen hinsichtlich der Akkumulation und Detektion von Fahrstreifenbegrenzungsverläufen. Zum einen konnte die Akkumulation der in den Videobildern semantisch klassifizierten Pixel der Fahrstreifenbegrenzungen in je nach Begrenzungstyp separaten Grid-Layern gezeigt werden und zum anderen wurde die Detektion von Fahrstreifenbegrenzungen auch für querende Richtungen integriert, so dass auch Abzweige und Haltelinien erkannt werden.

Konkret werden die semantisch klassifizierten Pixel durch invers perspektivische Projektion entsprechend ihrer semantischen Klasse in den jeweiligen Grid-Layer projiziert und dort akkumuliert. Dies ist in Abbildung 21 schematisch dargestellt. Hierzu ist eine sehr präzise Kompensation der Eigenbewegung und insbesondere der Aufwabbewegung des Ego-Fahrzeugs gegenüber der Akkumulationsebene notwendig.




Abbildung 21: Schematische Darstellung der Akkumulation im semantischen Grid


Im ersten Schritt werden über eine invers perspektivische Projektion auf die Bodenebene die Bilddaten in Weltkoordinaten überführt. Dies erfolgt für Bildbereiche, die auf Basis der semantischen Information relevante Klassen (z.B. Fahrstreifenmarkierung) oder Klassenübergänge (z.B. Grasnarbe) enthalten. Für die lokale Umgebung wird dann über die Zeit für jeden relevanten Begrenzungstyp dessen Wahrscheinlichkeit mit Hilfe einer Gitterkarte geschätzt.

Im zweiten Schritt werden aus den Akkumulationsergebnissen Hypothesen möglicher Begrenzungsverläufe extrahiert. Dies geschieht über eine systematische Variation von Verläufen in zwei Vorzugsrichtungen und zwar entlang und orthogonal zur prädierten Fahrzeugtrajektorie. Hierbei wird nach Verläufen gesucht, die in der lokalen Umgebung ein Maximum bzgl. der Wahrscheinlichkeit darstellen.

Die Projektion in eine Ebene ist dabei nur eine Näherung, welche bei stärkeren Unebenheiten mit steigender Entfernung an ihre Grenzen stößt. Diese wird mittelfristig durch eine implizite Schätzung der Oberfläche ersetzt werden müssen.

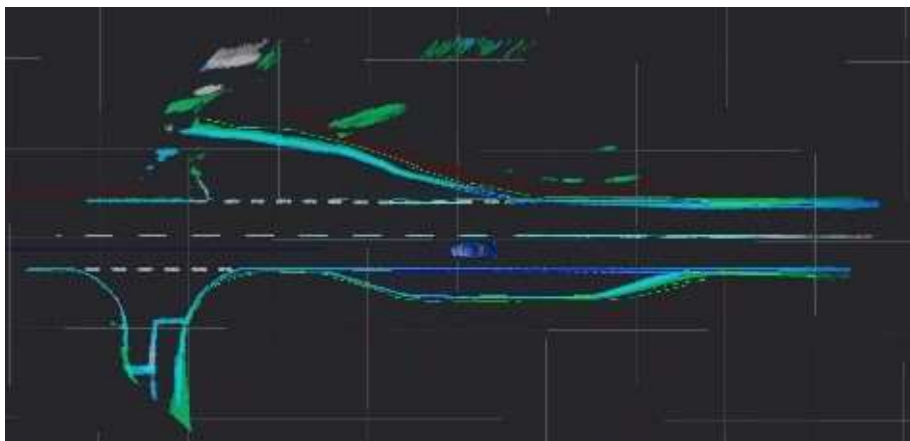
In der nachfolgenden Abbildung 22 sind drei Beispiele der im Vergleich Abbildung 20 neuen kompakteren Visualisierung der Semantischen Gridkarte mit den semantischen Klassen „dashed line“ (weiß), „solid line“ (cyan), „nature“ (grün), „static obstacle“ (red) zu sehen. Ferner sind das Ego-Fahrzeug und seine Trajektorie als dunkelblaue Linie

ingezeichnet. Immer an den Rändern des Grids sieht man wie Projektionsfehler zu Akkumulationsverwaschungen führen können, je weiter die Akkumulation vom Sensor entfernt ist, wenn die Ebenen-Annahme nicht stimmt oder die Ego-Kompensation des Aufbaus leicht fehlerhaft ist.



a) Kreisverkehr

b) Einmündung mit Haltelinie



c) Bushaltestelle

Abbildung 22: Semantisches Grid a) Kreisverkehr b) Einmündung c) Bushaltestelle

Tracking von Fahrstreifenbegrenzungen und Fahrstreifenbildung

Die sensorische Fahrstreifenerkennung wurde für den urbanen Bereich mit sehr kleinen Begrenzungssegmenten und kleinen Krümmungsradien komplett neu modelliert. Abweichend von dem bisher insbesondere auf Autobahnen und Landstraßen verwendeten, mit dem Ego gekoppelten mitgeführten Klothoiden, welche mittels Extended Kalman Filterung als 3D-Beschreibung des geometrischen Verlaufs im Raum geschätzt wurden, wurde nun eine ortsfeste Beschreibung kurzer typspezifischer Begrenzungssegmente als aufeinanderfolgende Segmentketten eingeführt. In Abbildung 24 und Abbildung 26 sind in einer Debug-Visualisierung die ortsfesten Begrenzungssegmente in grün und die Grenzen zwischen den Segmenten als kleine gelbe Striche zu erkennen. Die grünen Segmente sind ferner in der Historie

gespeichert, wohingegen die in dem grauen Kasten weißen Segmente aktuell neu generierte erkannte Fahrstreifengrenzen im Sichtbereich der zentralen Frontkamera sind. In **Fehler! Verweisquelle konnte nicht gefunden werden.** und Abbildung 25 sind die getrackten Fahrstreifengrenzen farblich entsprechend ihrer durch die semantische Segmentierung ermittelten Klasse dargestellt. In Blau sind die durchgezogenen Linien, in Grün Grenzen von Asphalt zur Natur und in Cyan gestrichelte Linien eingezeichnet.

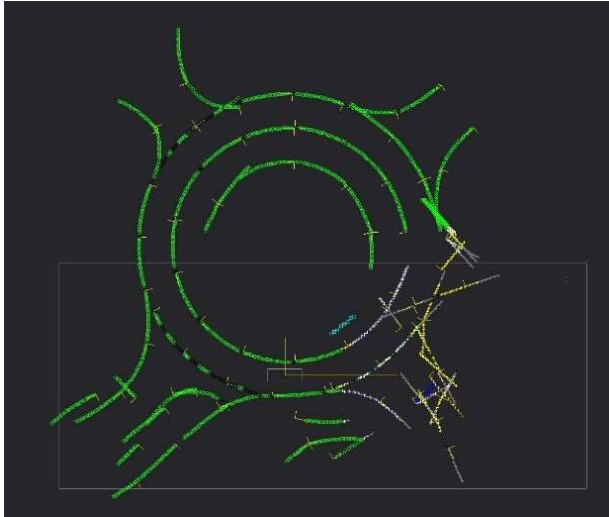


Abbildung 23: Debugausgabe der gehaltenen ortsfesten Tracks (grün), Segmentgrenzen (kurze gelbe Linien), akute Tracks (weiß+gelb) und nicht assoziiert (blau)




Abbildung 24: Sensorische Fahrstreifenerkennung mit semantischen Klassen am Kreisverkehr in Aldenhoven




Abbildung 25: Debugausgabe Bushaltestelle




Abbildung 26: Sensorische Fahrstreifenerkennung mit semantischen Klassen an Bushaltestelle

In Abbildung 27 und Abbildung 28 sind jeweils die erkannten ortsfest getrackten Fahrstreifengrenzen als Overlay zu dem originalen Videobild dargestellt.




Abbildung 27: Overlay der Fahrstreifengrenzen ins Videobild an einem Abzweig



Abbildung 28: Overlay der Fahrstreifengrenzen ins Videobild an einem Kreisverkehr

Damit sind kurze Segmente, variable Begrenzungstypen, kleine Begrenzungsdiskontinuitäten und enge Kurven abbildbar. Aktuell geht dies allerdings noch auf Kosten der Glattheit der Begrenzungsverläufe und es stellt die Fahrstreifenbildung vor größere Herausforderungen. Wie in der Abbildung 29 und Abbildung 30 zu sehen ist, weisen die Fahrbahnen bei der Verknüpfung der Fahrstreifengrenzen zu Fahrstreifen und der Verknüpfung der Fahrstreifen zu Fahrbahnen noch Lücken auf, so dass aktuell auf ein topologisches Vorwissen durch eine digitale Karte noch nicht verzichtet werden kann.

Der Plausibilisierung der digitalen Karteninformation mittels typklassifizierter kurzer Fahrstreifensegmente kommt die neue Repräsentationsform allerdings entgegen, da es viel einfacher ist für kleine Segmente Ähnlichkeitsmaße zu bestimmen als im Vergleich für sehr lange Verläufe, welche nur z.B. in Teilen Abweichungen aufweisen. Details zur Plausibilisierung finden sich im Firmenbericht zu Teilprojekt 2 im Unterkapitel zur Plausibilisierung.




Abbildung 29: Fahrstreifenbildung am Kreisverkehr




Abbildung 30: Fahrstreifenbildung an Bushaltestelle

Car2x Anbindung von Ampelphasen und Blinkerstatus

Ein weiteres Ergebnis war die erfolgreiche Anbindung der Ampeln mittels Car2x in Aldenhoven.

Car2X kommt an zwei Stellen bei der @CITY Abschlussdemo zum Einsatz. Zum einen hat der Audi Versuchsträger von der K2 Lichtsignalanlage (siehe Abbildung 31) die Ampelphase über Car2X bekommen. Der zweite Einsatz erfolgt bei dem Kooperationsszenario mit dem MAN-Bus. Der Blinkerstatus der MAN-Bus LED-Blinker war mit den beim Audi Versuchsträger zum Einsatz kommenden Kameras nicht robust erkennbar. Deswegen wurde der Blinkerstatus per Car2X vom Bus an den Audi Versuchsträger übertragen.

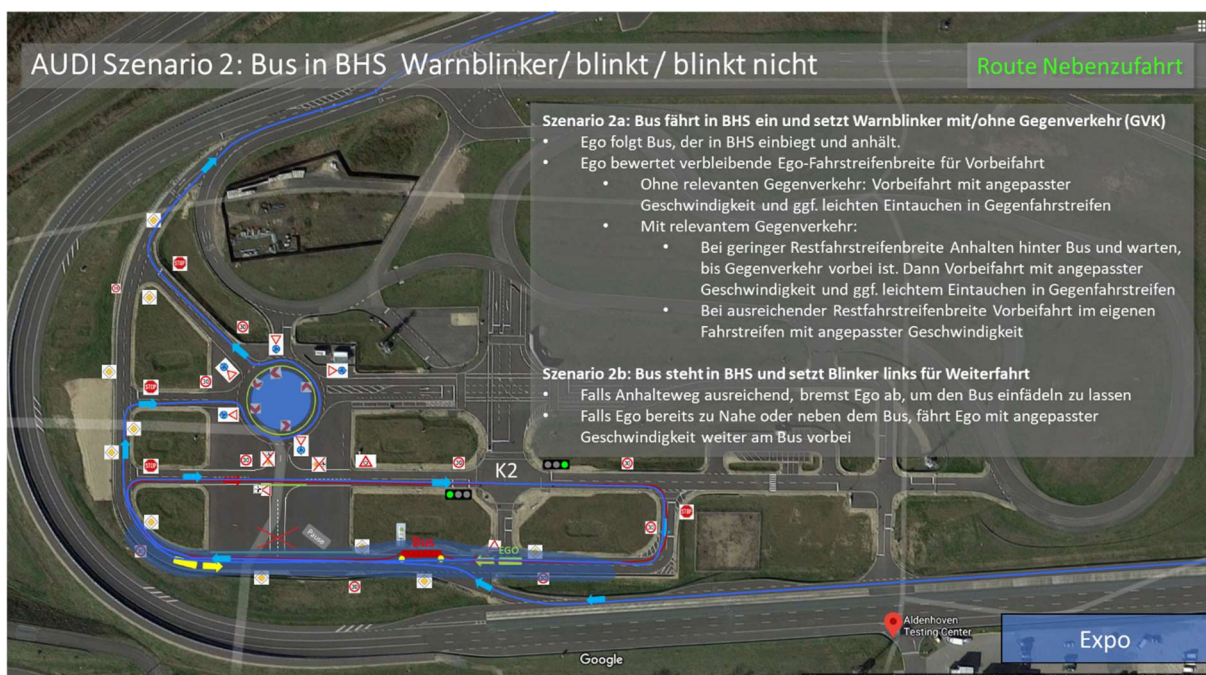


Abbildung 31: Szenario von der @CITY Abschlussdemo bei dem Car2X genutzt wird

Um die Car2X Signale empfangen zu können, wurden die Audi Versuchsträger mit einer Car2X Unit (waveBEE von nordsys) ausgestattet. Die Car2X Unit wurde so in den Versuchsträger integriert, dass die empfangen Signale im Verarbeitungsframework zur Verfügung stehen.

1.1.2.3 UAP1.2.3 – Hindernisse, Bekannt-, Belegt- und Unbekanntträume

Im Projekt @CITY hat Audi in den Versuchsträger 6 Laserscanner, die einen 360°-Lasergürtel bilden, in das Objekttracking integriert. Auf Basis der zueinander kalibrierten Laserrohdaten konnten neben dem in einer Belegungskarte akkumulierten statischen Umfeld auch die dynamischen Objekte rund um das Fahrzeug früher und durchgängig in ihrer Lage und Bewegung vermessen und verfolgt werden.

In den nachfolgenden Abbildung 32 sind die Einbaulage, Sichtbereiche und eine Gegenüberstellung der Akkumulation in einer Belegungskarte eines Frontsensors gegenüber einem 360° Lasergürtel veranschaulicht.

6 x Valeo Scala




Abbildung 32: 360° Lasergürtel bestehend aus 6 Laserscannern. Links) Einbaulage der Sensoren, Rechts) Überlagerung der Laserentfernungspunkte in farblicher Codierung je Sensor

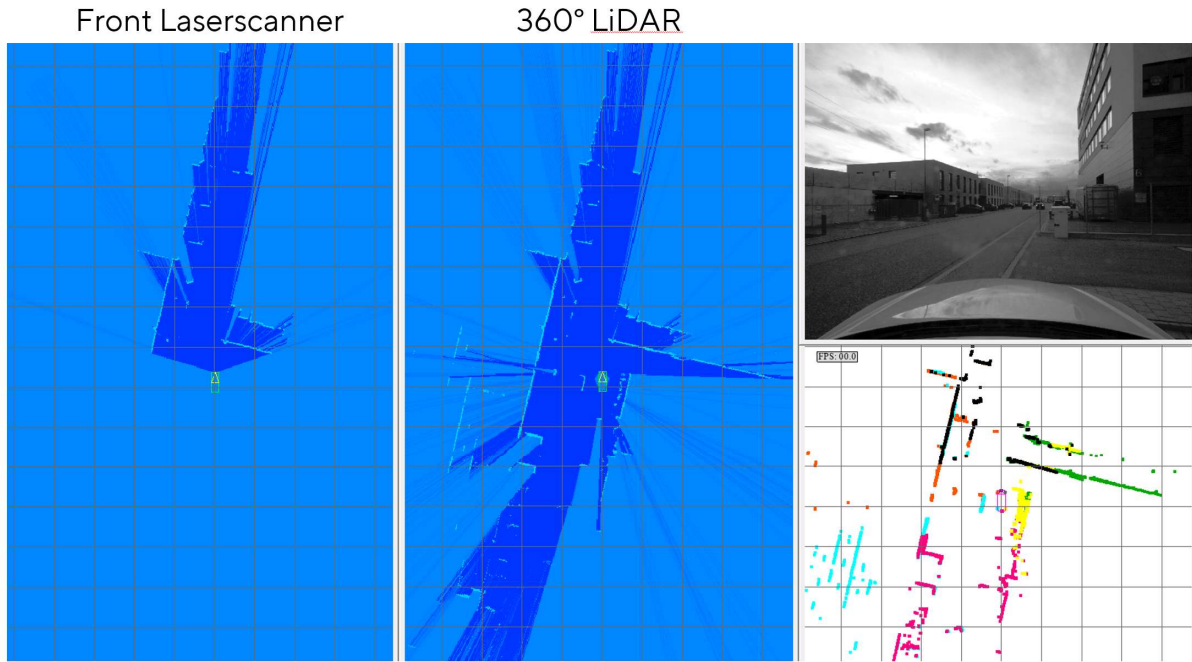


Abbildung 33: Gegenüberstellung der Belegungskarte eines Einzelsensor zu 360° Lasergürtel bei Anfahrt aus dem Stand

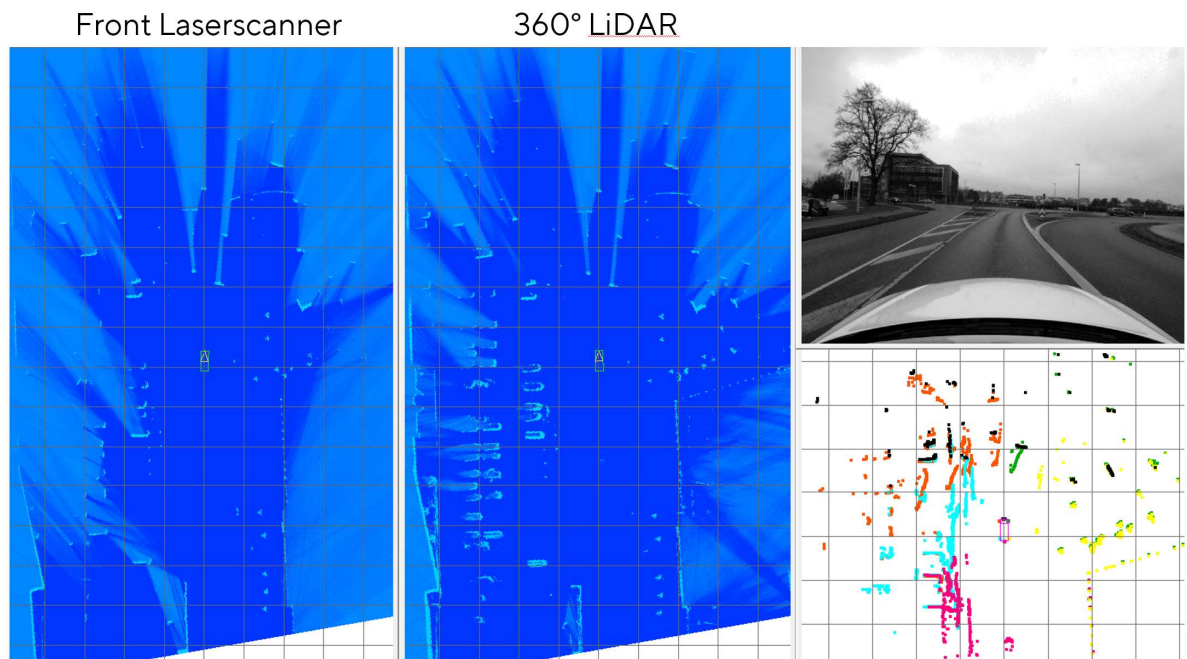


Abbildung 34: Gegenüberstellung der Belegungskarte eines Einzelsensor zu 360° Lasergürtel während der Fahrt

In der Belegungskarte sind die deutlich verbesserte Konturakkumulation und Details von parkenden Fahrzeugen, die reduzierten Unbekanntbereiche und erweiterten Freibereiche in größerer Entfernung erkennbar. Ferner können nun natürlich neben dem statischen Umfeld auch die dynamischen Objekte früher und durchgängiger getrackt werden.

1.1.2.4 UAP1.2.4 – Erkennung dynamischer Verkehrsteilnehmer

Um die 6 Laserscanner, die in der Stoßstange Front, Front-Left, Front-Right, Rear, Rear-Left, Rear-Right verbaut wurden, korrekt in das Objekttrackingmodul zu integrieren, wurde das bestehende Messmodell zunächst zu einem Einbaulagen-unabhängigen Messmodell zum Tracking bewegter Verkehrsteilnehmer erweitert.

Die Vorteile bei urbanen Kreisverkehr- und Kreuzungsszenarien liegen insbesondere darin, dass nun querende Fahrzeuge im erweiterten Field-of-View gegenüber dem Standard Front-Lidar deutlich früher und länger sichtbar sind. In Abbildung 35 sind nachfolgend zwei Screenshots der Laserrohdaten des 360° Lasergürtels dargestellt.




Abbildung 35: Laserrohdaten des 360° Lasergürtels bestehend aus 6 Laserscannern mit jeweils 145° Öffnungswinkel. In Weiß sind statische Laserpunkte, in Rot als dynamisch klassifizierte Laserpunkte und in Gelb sind getrackte Objekte dargestellt.

Neben den Laserrohdaten hatten wir uns noch zum Ziel gesetzt unser Objekttracking auch um die Möglichkeit zur Einspeisung von Radialgeschwindigkeiten aus Radarrohdetektionen zu erweitern. Auch diesen Punkt konnten wir umsetzen.

Insbesondere wurden dazu entsprechende Verfahren zur Selektion und Assoziation von Radar-Locations zu bestehenden Tracks implementiert. Die nachfolgende Abbildung 36 zeigt links das Videobild der Szene und rechts in Gelb: die Objekttracks, in Rot: die Radar-Detections mit Radialgeschwindigkeit und in Grün: den Punkt, zu dem Locations assoziiert werden und das zugehörige Residuum.



Abbildung 36: links) das Videobild der Szene und rechts) in Gelb die Objekttracks, in Rot: Radar-detections mit Radialgeschwindigkeit und in Grün: den Punkt, zu dem Locations assoziiert werden und das zugehörige Residuum

Ferner wurde im Rahmen des @CITY-Förderprojekts ein Konzept zur sensorspezifischen Sichtbarkeitsanalyse entwickelt und implementiert. Dies dient zur Plausibilisierung von Objekthypothesen und verbessert gleichzeitig die Objektverfolgung in komplexen Szenarien, wie beispielsweise Kreisverkehren mit Verdeckung.

Abbildung 37 zeigt die Analyse, welche Referenzpunkte eines Fremdobjekts unter Berücksichtigung des Strahleinfallwinkels eines Lasersystems sichtbar sind. In Grün sind sichtbare Referenzpunkte und in Rot die nicht sichtbaren Referenzpunkte. Ferner wird die Verdeckungsrechnung unter Berücksichtigung von Fremdobjekten gezeigt. Die beiden blauen Linien begrenzen den Verdeckungsbereich bzw. „Schatten“, der vom Objekt im Vordergrund geworfen wird. Beim Objekt hinten rechts sind dann die Referenzpunkte weiß markiert, die laut Einfallswinkel sichtbar wären, aber im verdeckten Bereich liegen und daher als nicht sichtbar klassifiziert werden.




Abbildung 37: zeigt eine Analyse, welche Referenzpunkte eines Fremdobjekts sichtbar sind unter Berücksichtigung des Strahleinfallwinkels. Grün sind sichtbare Referenzpunkte und Rot die nicht sichtbaren Referenzpunkte. Ferner wird die Verdeckungsrechnung unter Berücksichtigung von Fremdobjekten gezeigt. Die beiden blauen Linien begrenzen den Verdeckungsereich/Schatten, der vom Objekt im Vordergrund geworfen wird. Beim Objekt hinten rechts sind dann die Referenzpunkte weiß markiert, die laut Einfallswinkel sichtbar wären, aber im verdeckten Bereich liegen und daher als nicht sichtbar klassifiziert werden.

Zur robusteren Objektverfolgung von Fremdfahrzeugen mit stark variierender Perspektive, wie beispielweise querendem Verkehr mit dem Ego-Fahrzeug an der Haltelinie eines Kreisverkehrs, wurde das Konzept zur Längen- und Breitenschätzung überarbeitet.

Zur Verbesserung der Objektdetektion und des Trackings insbesondere bei Querverkehr wurden außerdem die für Autobahn vertretbaren Annahmen hinsichtlich der urbanen Szenarien hinterfragt, ob dieses sowohl für Längs- als auch Querverkehr geeignet sind. Im Rahmen dieser Prüfung wurden die Mechanismen so überarbeitet werden, dass diese sowohl für Längsverkehr als auch Querverkehr funktionieren. So lieferten die für den Längsverkehr optimierten Frontradsensoren oftmals nur

stehende Objekte, wenn Fahrzeuge z.B. in einem Kreisverkehr quer an einem vorbeifahren. Die klassische Bildverarbeitung, die oftmals auf Symmetrien von einer Heckansicht basiert, funktioniert bei Fahrzeugen in der Queransicht auch nur bedingt. Um für die Seitenansicht ein stabiles Tracking zu bekommen, wurde im Projekt versuchsweise ein Raddetektor auf Basis von Machine Learning entwickelt. Die Ergebnisse des ML-Detektors sind exemplarisch in Abbildung 38 und Abbildung 39 dargestellt.




Abbildung 38: Beispiel 1 für ML Raddetektor (rotes Rechteck mit Mittelpunkt, grünes Polygon ist Rückprojektion des getrackten Objekts ins Videobild)



Abbildung 39: Beispiel 2 für ML Raddetektor (rotes Rechteck mit Mittelpunkt, grünes Polygon ist Rückprojektion des getrackten Objekts ins Videobild)

Im Projekt wurde insbesondere auch hinsichtlich des Szenarios „Interaktion mit einem ÖPNV Bus an einer Bushaltestelle“ an der Detektion und dem Tracking des Busses gearbeitet. Hier wurden sowohl die semantische Klassifikation als Bus mittels CNNs optimiert, als auch die Detektion des Busses aus Laserentfernungs- und Radarrohdaten verbessert. Aus den Laser-Sensorrohdaten werden zunächst Cluster unter Verwendung der semantischen Klassifikation gebildet, woraus dann Bushypothesen generiert werden, welche dann mittels dynamischer Modelle in einem Extended Kalman Filter hinsichtlich ihrer Ausdehnung und dynamischer Zustände getrackt werden. In Abbildung 40 sind links die aus dem Rohdaten-Cluster gebildete Bus-Hypothese und rechts die ins semantisch klassifizierte Bild rückprojizierten Laserentfernungsdaten zu sehen. In Abbildung 41 sieht man einen getrackten Bus am Kreisverkehr. Es ist zu erkennen, dass bei langen Objekten bezüglich des Bewegungsmodells und der nachlaufenden Hinterachse für zukünftige Projekte noch Verbesserungspotentiale zu heben sind.




Abbildung 40: links: Bus-Hypothese aus Rohdaten, rechts: Semantisch klassifiziertes Bild mit ins Bild rückprojizierten Laserentfernungsdaten




Abbildung 41: Tracking des Busses am Kreisverkehr, Es bestehen noch Herausforderungen bei langen Objekten bezüglich Bewegungsmodell und nachlaufender Hinterachse

1.1.3. AP1.3 – Situationsverstehen

1.1.3.1 UAP1.3.1 – Topologieverständnis und Verkehrsführung

In @CITY hatten wir uns zum Ziel gesetzt, a priori Karteninformation nicht einfach ungeprüft zu nutzen, sondern vorher zumindest mit sensorischer Umfelderkennung zu plausibilisieren. Dieser Schritt ist nun im Rahmen von Teilprojekt TP2 im Arbeitspaket Plausibilisierung digitaler Karteninformation erfolgt, so dass als Basis für das Situationsverstehen nun in den Grenzen der sensorischen Vorausschau plausibilisierte Information zu Einsatz kommt.

Bei der Plausibilisierung werden dabei getrackte Linien aus der Wahrnehmung zyklisch mit a-priori-Daten aus der Karte assoziiert. Dazu wird ein Joint compatibility branch and bound (JCBB) Algorithmus verwendet. Die Assoziationen und die zugehörige Fehlermetrik werden als Güte der Übereinstimmung abgespeichert. Dadurch wird für die Kartenlinien jeweils eine Historie aufgebaut. Die Plausibilität von Teilabschnitten der Kartenlinien wird mittels der Historie bestimmt. Dazu wird für jeden Teilabschnitte die kleinste Fehlermetrik (= beste Übereinstimmung) der dazugehörigen Assoziationen aus der Historie ermittelt.

Die a priori Karteninformation wird dazu in einen Roadgraph überführt, der mittels der Güte Maße annotiert wird. In

Abbildung 42 ist der Roadgraph in Rot zu sehen. Die in Grün annotierten Fahrstreifengrenzen stellen die durch sensorische Wahrnehmung plausibilisierten Begrenzungsverläufe dar.




Abbildung 42: Mittels sensorischer Fahrstreifenenerkennung plausibilisierter Roadgraph in grün

Im Roadgraph bereits enthalten ist die Topologie und statische Vorfahrtregelung und Geschwindigkeitslimits entlang gültiger Bahnen. Der Roadgraph wird weiter durch C2X-Ampelinformation oder sensorischer Ampelphasenerkennung um dynamische Vorfahrtsregelungen erweitert. Zusätzlich werden den Pfaden des Roadgraphen die erkannten dynamische Objekte rund um das Ego zugeordnet.

Dieses im Nahbereich plausibilisierte gesammelte und mit der digitalen Karte für eine größere Vorausschau verknüpfte Wissen zur Topologie, Vorfahrtsregeln und Geschwindigkeitslimits bildet zusammen mit dem statischen Hindernissen in der Belegungskarte und den erkannten dynamischen Objekten die Wissensbasis für die Prognose der zukünftigen Verhaltensweisen und Vorhersage der Trajektorien der anderen Verkehrsteilnehmer.

1.1.3.2 UAP1.3.2 – Intentionen und Verhaltenserkennung

Im Rahmen des Förderprojektes wurde für das Szenario eines in einen Kreisverkehr einfahrenden Fahrzeugs ein Ansatz zur Bestimmung einer zumutbaren Verzögerung im Kooperationsfall für ein Fahrzeug mit Vorfahrt im Kreisverkehr untersucht. Dabei wurde bewertet, ob das Fahrzeug im Kreisverkehr allein durch leichtes „vom Gas gehen“ die für die Einfahrt notwendige Zeitlücke erzeugen könnte. Wenn dies rechnerisch möglich war, wurde dem Fahrzeug im Kreis hypothetisch in der Prognose unterstellt, dass er dies auch tun würde. Der Planer nutzte diese kooperative Prognose dann, um das Einfahren des Ego zu bewerten. Problematisch hat sich allerdings herausgestellt, dass bei insbesondere größere Unsicherheiten in der Schätzung der Objektzustände aufgrund der Umfeldwahrnehmung es zu sprunghaften Änderungen in der Prognose kommen kann, wodurch der Planer gegebenenfalls stark bremsen würde, um ein sicheres Verhalten zu generieren. Deshalb ist das Fazit, dass der Planer zukünftig sowohl eine kooperative als auch eine nicht-kooperative Prognose gleichzeitig entsprechend mit Wahrscheinlichkeiten in die Planung mit einbeziehen müsste, um mit beiden Möglichkeiten mit angepasster vorausschauender Reaktion umgehen zu können.

Für den Kreisverkehr wurden Drohnenaufnahmen gemacht und die kinematischen Größen realer Verkehrsteilnehmer aus den Drohnenaufnahmen extrahiert, um diese als Basis zur Abstimmung und Bewertung der Parameter maschinell gelernten Klassifikatoren zu verwenden. Ferner wurden auf Basis der extrahierten Trajektorien typische Bahnen und Geschwindigkeitsprofile von Fahrzeugen beim Durchfahren von Kreisverkehren erzeugt.

Dies ist beispielhaft in **Fehler! Verweisquelle konnte nicht gefunden werden.** und Abbildung 44 zu sehen.




Abbildung 43: Luftbildaufnahme aus Drohnensequenz mit Objekttraces und Id's




Abbildung 44: Extrahierte Trajektorien akkumuliert über 20min Sequenzen aus Drohnenaufnahmen

Im Rahmen einer Doktorarbeit wurde z.B. die Klassifikation der Intention von Fahrzeugen im Kreisverkehr hinsichtlich „Kreisverkehr verlassen“ oder möchte „im KV bleiben“ untersucht.

Dazu gab es eine Veröffentlichung der Ergebnisse auf der VEHITS-Konferenz im April 2020. Für das Paper „Classification of Driver Intentions at Roundabouts“ (Autoren: Moritz Sackmann, Henrik Bey, Ulrich Hofmann und Jörn Thielecke) wurde der „Best Student Paper Award“ verliehen.

Ziel der Arbeit war es, möglichst frühzeitig festzustellen, ob ein Fahrzeug einen Kreisverkehr verlässt. Dafür wurden zwei Ansätze eingeführt. Der erste Ansatz nutzt vorherige Beobachtungen anderer Fahrzeuge an demselben Kreisverkehr, um ein Verhaltensmodell für „Kreisverkehr verlassen“ und eins für „im KV bleiben“ aufzustellen. Abbildung 45 zeigt typische Intentionen im Kreisverkehr. Der zweite Ansatz erzeugt synthetische Verhaltensmodelle. Dafür wird ausschließlich eine präzise Karte benötigt, folglich kann der Ansatz ohne vorherige Beobachtungen auf neue Kreisverkehre übertragen werden. Abbildung 46 zeigt aus kartierten Randverläufen synthetisch generierte typische Trajektorien und zusätzlich darunter als feine rote oder blaue Linien reale Bahnen aus Drohnenaufnahmen.

Anschließend erfolgt die Klassifikation durch den Vergleich eines beobachteten Fahrzeugs mit den Verhaltensmodellen für „Kreisverkehr verlassen“ und „im KV bleiben“. Das Ergebnis ist die Wahrscheinlichkeit, dass der Kreisverkehr verlassen wird. Siehe Abbildung 47.

Die Methoden werden anhand von 250 echten Trajektorien verifiziert und ermöglichen die Erkennung der Intention ca. 5-10 Meter vor der Ausfahrt.




Abbildung 45: Intentionen: "Bleibt im Kreis" bzw. "verlässt den Kreis" bzw. "fährt in den Kreis ein"




Abbildung 46: Trajektorien im Kreisverkehr

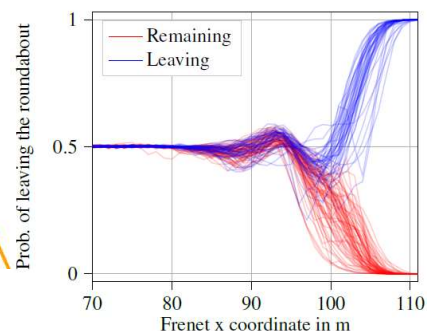


Abbildung 47: Geschätzte Verlassenswahrscheinlichkeiten für die Trajektorien

Als weiteren möglichen Ansatz zur Verbesserung der Objektprädiktion in Kreisverkehrsszenarien wurde ein binärer Klassifikator zur Bewertung der Einfahrtsentscheidung eines Verkehrsteilnehmers in den Kreisverkehr entwickelt. Der Zweck des Klassifikators ist die Bewertung des Szenarios bei dem an der Kreisverkehreinfahrt zwei Fahrzeuge - eines im Kreis und eines auf der Einfahrt - in einem Konflikt zueinanderstehen und bewertet werden muss, welches Fahrzeug vor

dem anderen weiterfahren wird. Es wurden bei der Entwicklung verschiedene Merkmale der beiden Fahrzeuge analysiert und für eine gute Separation der unten definierten Klassen wurden die beiden folgenden Merkmale ausgewählt:

- $\Delta s = \text{Abstand Fahrzeug A} - \text{Abstand Fahrzeug B zum Ende des Konfliktbereichs}$
- $\Delta v = \text{Geschwindigkeit Fahrzeug A} - \text{Geschwindigkeit Fahrzeug B}$

Als Methode für den Klassifikator wurde eine Support-Vector-Machine gewählt, die auf Basis von Drohnendaten trainiert wurde. Aus den Drohnendaten wurden alle Objekttrajektorien extrahiert und auf eine digitale Karte projiziert, so dass Konflikte zwischen Objekten anhand der Kartentopologie erkannt werden konnten. Daraus ergaben sich vier mögliche Klassen für ein Objekt:

1. Objekt an der Einfahrt, fährt vor dem Konfliktfahrzeug in den Kreisverkehr (grün)
2. Objekt an der Einfahrt, fährt nach dem Konfliktfahrzeug in den Kreisverkehr (rot)
3. Objekt im Kreisverkehr, fährt vor dem Konfliktfahrzeug (blau)
4. Objekt im Kreisverkehr, fährt nach dem Konfliktfahrzeug (gelb)

Die nachfolgende Abbildung 48 zeigt die vier Klassen in jeweils einer Farbe und die relativ gute Separation der Daten.




Abbildung 48: Verteilung und Traces der vier zu separierenden Objektklassen

In dieser Darstellung existiert für jeden Datenpunkt ein punktgespiegelter Datenpunkt, der die Formeln für die Differenz des Abstandes und der Geschwindigkeit aus der Sicht des jeweiligen Konfliktpartners beschreibt. Weiter ist es besonders wichtig die grün dargestellten Datenpunkte von den rot dargestellten zu separieren, da das dem Objekt an der Kreisverkehreinfahrt entspricht, das entweder anhält oder in den Konfliktbereich einfährt. Aufgrund dessen werden in der nachfolgenden Abbildung 49 nur noch die Klassen der grünen (links im Bild) und roten (rechts im Bild) Datenpunkte

dargestellt (jedoch in anderen Farben). Zudem wurden deutlich mehr Datenpunkte verwendet. Die trainierte Support-Vector-Machine mit linearem Kernel trennt die beiden Klassen mit einer sehr hohen Richtigklassifikationsrate von 98.837 Prozent. Für eine hundertprozentige Richtigklassifikationsrate müssten alle weißen Punkte im weiß eingefärbten Bereich liegen sowie alle grün eingefärbten Punkte im grün eingefärbten Bereich. Man kann in Abbildung 49 häufig mehrere Punkte, die zusammen eine Linie ergeben, erkennen. Diese Linien entsprechen dem zeitlichen Ablauf eines Einfahrtskonflikts zweier Fahrzeuge mit mehreren aufeinander folgenden Messungen. Falls eine solche Linie am Anfang falsch klassifiziert sein sollte und damit im Bereich mit der jeweiligen anderen Hintergrundfarbe, so wandert sie im zeitlichen Verlauf in jedem Fall in die richtige Klasse.




Abbildung 49: Hyperebene zur Klassifikation der wahrscheinlichen Einfahrtsreihenfolge mittels Support-Vector-Machine zur Einfahrtsentscheidung („Anhalten oder Einfahren“)

Um die binäre Einfahrtsentscheidung im Zusammenspiel mit anderen Prädiktionsmechanismen zu nutzen, kann der Abstand zur Hyperebene der einzelnen Datenpunkte in eine Wahrscheinlichkeit übersetzt werden.

1.1.3.3 UAP1.3.3 – Modellierung von Beziehungen und Wechselwirkungen

Im Laufe des @CITY Projektes hat sich gezeigt, dass UAP 1.3.3 und UAP 1.4.2 sehr eng verwandt sind. Deshalb werden die Ansätze zur Modellierung und Prognose im Kapitel 1.1.4.2 gemeinsam präsentiert.



1.1.3.4 UAP1.3.4 – Repräsentation von relevantem Wissen

Zur Repräsentation und Verknüpfung der Fahrbahninfrastrukturinformation mit den dynamischen Objekten, der Route und den Prognosen der dynamischen Objekte wird bei Audi ein Roadgraph verwendet.

Im Roadgraph laufen die Informationen zur Topologie der Fahrstreifen aus der digitalen Karte, die statische Vorfahrtregelung und Geschwindigkeitslimits entlang gültiger Bahnen zusammen. Der Roadgraph wird weiter durch C2X-Ampelinformation oder sensorischer Ampelphasenerkennung um dynamische Vorfahrtsregelungen erweitert. Zusätzlich werden den Pfaden des Roadgraphen die erkannten dynamische Objekte rund um das Ego zugeordnet.

Dieses im Nahbereich plausibilisierte gesammelte und mit der digitalen Karte für eine größere Vorausschau verknüpfte Wissen zur Topologie, Vorfahrtsregeln und Geschwindigkeitslimits bildet zusammen mit dem statischen Hindernissen in der Belegungskarte und den erkannten dynamischen Objekten die Wissensbasis für die Prognose der zukünftigen Verhaltensweisen und Vorhersage der Trajektorien der anderen Verkehrsteilnehmer. In der Belegungskarte sind ferner auch die Bereich extrahierbar, welche durch die Sensorik insbesondere die 360° Laserscanner bisher nicht exploriert werden konnten, d.h. noch unbekannt bzw. verdeckt sind.

Das Wissen über unbekannte Bereiche und fehlendes relevantes Wissen z.B. über potentielle dynamische Objekte in verdeckten Einmündungsbereichen ist für vorausschauendes kooperatives Fahren zukünftig im Planungsmodul noch zu berücksichtigen.

1.1.4. AP1.4 – Prognose

Es wurden im Rahmen des Projektes mehrere entwickelte Methoden zur Prognose in den Software-Stack im Audi Versuchsträger integriert. Im Rahmen von @CITY lag der Fokus bei Audi auf Fahrzeugen, so dass insbesondere für jedes erkannte dynamische Fahrzeug entsprechend seiner Fahrtrichtung zunächst die möglichen Bahnen unter Verwendung des Roadgraphen bestimmt wurden.

Für die möglichen Bahnen wurden dann in Abhängigkeit von den Krümmungsverläufen, den Geschwindigkeitsbegrenzungen und den Vorfahrtsregeln entlang der möglichen Bahnen realistische Geschwindigkeitsprofile für die Prognose generiert. Die möglichen prognostizierten Bahnen sind in Abbildung 50 in Blau dargestellt, wohingegen die Geschwindigkeitsverläufe mit der Geschwindigkeit als z-Komponente in Grün visualisiert sind. Im aktuellen System werden außer Folgefahrt keine Interaktionen zwischen den Prognosen berechnet. Fahrzeuge hinter dem Ego erhalten aktuell keine Prognose. Das Ego ist in Dunkelblau dargestellt. Der Planer nutzt die Prognosen, um für das Ego geeignete Trajektorien entlang der geplanten Route zu finden.

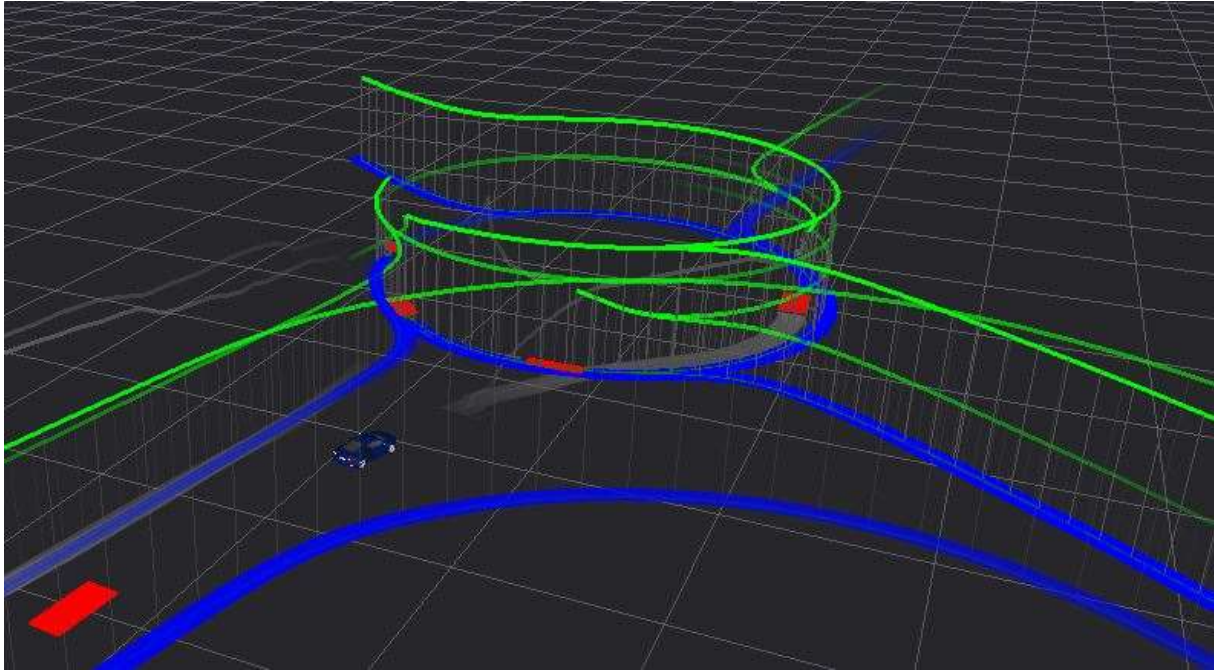


Abbildung 50: Visualisierung der Prognosen entlang der möglichen Bahnen in blau, Geschwindigkeitsprofile in grün und Historien in grau. Das Ego-Fahrzeug ist in dunkelblau dargestellt.

Nichtsdestotrotz haben wir uns mit dem Thema Modellierung von Verhaltensmuster unter Berücksichtigung von Interaktionen beschäftigt. Die Ansätze und Ergebnisse sind in Kapitel 1.1.4.2 bzw. in den dazugehörigen Veröffentlichungen zu finden.

1.1.4.1 UAP1.4.1 – Generierung von Verhaltensprognosen

Im Verlauf des Projektes @CITY hat sich herausgestellt, dass die Generierung von Verhaltensprognosen schon in UAP1.3.2 Intentionen und Verhaltenserkennung benötigt wurde, um durch den Vergleich gemessener Objekthistorien mit synthetisch für die aktuelle Umgebung generierten Trajektorien auf die Intention zu schließen, d.h. z.B. beim Befahren eines Kreisverkehrs zu klassifizieren, ob ein Fahrzeug in einem Kreisverkehr bleibt oder diesen verlässt. Deshalb wurde dieser Arbeitspunkt in UAP1.3.2 beschrieben. Ferner sind auch in UAP1.4.2 bei der Inferenz mittels der gelernten Driving Policies entsprechende Ansätze zu finden.

1.1.4.2 UAP1.4.2 – Prognose der dynamischen Szene mit Wechselwirkung

Im Rahmen eines Doktorandenprojekts wurden verschiedene Modelle zur Vorhersage des Verhaltens von Fahrzeugen entwickelt.

Im Paper „**Prediction Error Reduction of Neural Networks for Car-Following Using Multi-Step Training**“ (Autoren Moritz Sackmann, Henrik Bey, Ulrich Hofmann, Jörn Thielecke; veröffentlicht auf der IEEE ITSC 2020) wurde eine neue Methode zur Parametrierung von Fahrzeugfolgmodellen vorgestellt.

Ein schrittweises Verhaltensmodell sagt die nächste Handlung, z.B. die Beschleunigung und Lenkung, des Fahrers in Abhängigkeit von der Verkehrssituation



vorher. Ein Fahrzeugfolgemodell ist ein vereinfachtes Verhaltensmodell, das sich ausschließlich mit Folgefahrt befasst. Typischerweise wird die Beschleunigung des Fahrzeugs in Abhängigkeit von der Geschwindigkeit des Vorderfahrzeugs und des vorherzusagenden Fahrzeugs sowie der Distanz zwischen den Fahrzeugen vorhergesagt.

Von einer Ausgangssituation aus kann durch wiederholtes Aufrufen des Modells nicht nur die unmittelbar nächste Handlung vorhergesagt werden, sondern die Trajektorie, die beschreibt zu welchem Zeitschritt das Fahrzeug an welcher Stelle ist.

Bislang in der Literatur verbreitete Ansätze minimieren in der Regel nur den Vorhersagefehler über einen Zeitschritt, also die Abweichung zwischen vorhergesagter Beschleunigung und tatsächlicher Beschleunigung. Das hat den Nachteil, dass Fehler, die durch den rekursiven Modellaufruf entstehen, bei der Minimierung nicht berücksichtigt werden können.

Hier setzt die Idee des Papers an: Durch Minimierung des Vorhersagefehlers über mehrere Zeitschritte, d.h. die Abweichung zwischen den vorhergesagten Positionen des Fahrzeugs und der tatsächlichen Position, wird der Effekt von kaskadierten Fehlern deutlich abgeschwächt. Folglich weisen die so trainierten Modelle deutlich geringere Fehler als mit dem Einschritt-Verfahren trainierten Modelle auf.

Das neue Trainingsverfahren wird verwendet, um klassische Fahrzeugfolgemodelle wie z.B. das Intelligent Driver Modell (IDM) zu parametrieren. Zusätzlich wird es auch verwendet, um ein neuronales Netz zu trainieren, das mit denselben Eingangsdaten arbeitet und bessere Vorhersagen als das IDM liefert. Grund ist, dass ein neuronales Netz eine größere Flexibilität besitzt als ein parametrisches Modell und dadurch die Feinheiten menschlichen Fahrverhaltens besser abbilden kann.

Die geringe Anzahl an Eingangsgrößen von Fahrzeugfolgemodellen ist dabei ein zweischneidiges Schwert: Einerseits ermöglicht sie es, kompakte Modelle zu trainieren, deren Verhalten trotz der Nutzung von neuronalen Netzen noch interpretierbar und sogar durch gezieltes Erzeugen synthetischer Trainingsdaten beeinflussbar ist. Beispielsweise wurde der Trainingsdatensatz auf diese Weise um besonders kritische Situationen erweitert, damit das Fahrzeugmodell in diesen Situationen bremst.

Andererseits ist ein Fahrzeugfolgemodell nicht in der Lage, in komplexeren Verkehrssituationen mit mehreren anderen Fahrzeugen zu interagieren.

Daher war es nur folgerichtig, dass den Fokus danach auf aufwendigere Verhaltensmodelle zu übertragen. Diese Modelle sollen gleichzeitig auf mehrere andere Fahrzeuge reagieren können und zusätzlich ein an den Verlauf der Fahrbahn angepasstes Geschwindigkeitsprofil aufweisen.

Aufbauend auf den gerade vorgestellten Ansatz zur Vorhersage des Verhaltens von Fahrzeugen in Folgefahrszenarien wurde eine weitere Methode auf das Kreisverkehrsszenario adaptiert und auf der ITSC2021 mit dem Titel „**Multi-Step Training for Predicting Roundabout Traffic Situations**“ (Autoren: Moritz Sackmann,

Tobias Leemann, Henrik Bey, Ulrich Hofmann und Jörn Thielecke) veröffentlicht. Abbildung 51 illustriert das Kreisverkehrsszenario bei der Einfahrt aus der Sicht des schwarzen Fahrzeugs.




Abbildung 51: Illustration einiger relevanter Inputgrößen aus der Sicht des schwarzen Fahrzeugs. Das vorfahrtsberechtigige "conflicting" Fahrzeug ist in Rot dargestellt und das zum schwarzen Fahrzeug vorausfahrende Fahrzeug in Blau. Alle Entfernungen sind jeweils entlang der Centerlines der Fahrzeugbahnen definiert.

Eine detaillierte Liste der Eingangsgrößen findet sich in Tabelle 1.

TABLE I
FEATURES

Feature	Symbol	Unit
Velocity	v	m/s
Distance to left boundary	d_l	m
Distance to right boundary	d_r	m
Heading relative to lane	φ_0	rad.
Heading rel. to lane in 5 m	φ_5	rad.
Heading rel. to lane in 10 m	φ_{10}	rad.
Heading rel. to lane in 20 m	φ_{20}	rad.
Current road curvature	c	m^{-1}
Preceding vehicle's velocity	v_{pre}	m/s
Distance to preceding vehicle	d_{pre}	m
Distance to next yield line	d_{yield}	m
Conflicting vehicle's velocity	$v_{conf1,1}$	m/s
Distance of confl. veh. to conflict zone	$d_{conf1,1}$	m
2 nd conflicting vehicle's velocity	$v_{conf1,2}$	m/s
Distance of 2 nd confl. veh. to conflict zone	$d_{conf1,2}$	m

Die Übertragbarkeit des Ansatzes auf beliebige Kreisverkehre bzw. weitere urbane Szenarien ist hierbei eine wichtige Basisanforderung an alle verfolgten Ansätze.

Als POC (Proof of Concept) wurde deshalb untersucht inwiefern der entwickelte Ansatz mit den Eingangsgrößen aus Tabelle 1 in der Lage ist sicher einem beliebigen Straßenverlauf zu folgen. Es konnte gezeigt werden, dass das Fahrzeug seine Geschwindigkeit und vergleichbar zu einem menschlichen Fahrer seine laterale Position in der Straße intuitiv so, wie es andere Verkehrsteilnehmer erwarten würden, anpasst. Somit ist der Ansatz auf beliebige Geometrien mit typischen Krümmungsverläufen übertragbar (siehe Abbildung 52).




Abbildung 52: Das 8 Sek.-Vorhersage Modell fährt durch eine bisher ungesehene kurvige Strecke. Das Modell hat das typische Fahrverhalten menschlicher Fahrer gelernt: Immer innerhalb des Fahrstreifens bleiben, die Geschwindigkeit an den Kurvenradius zur Begrenzung der Quereschleunigung anpassen und natürlich die Kurven eng zu fahren, um die Fahrstrecke zu minimieren. Allerdings würden wir mit diesem Fahrer noch kein Taxiunternehmen starten, da die gefahrenen Quereschleunigungen noch nicht für eine komfortable Fahrt ausgelegt sind. Die Modelle, welche nur aufgrund eines kürzeren Vorausschauhorizonts angelernet wurden, erreichen diese Ziele nicht. Das ist ein klares Indiz des Performancegewinns durch die neue Methode. Die Fahrtrichtung wird durch den Pfeil angezeigt.

Die Ergebnisse eines weiteren Ansatzes zur Modellierung der Interaktionen und Prognose der Verkehrsteilnehmer an einem Kreisverkehr wurden auf der ITSC2021 mit dem Titel „**Parameter Sharing Reinforcement Learning for Modeling Multi-Agent Driving Behavior in Roundabout Scenarios**“ (Autoren: Fabian Konstantinidis, Moritz Sackmann, Oliver De Candido, Ulrich Hofmann, Jörn Thielecke und Wolfgang Utschick) veröffentlicht.

In dem Paper wurde diese Aufgabenstellung mittels Multi-Agent Reinforcement Learning (MARL) untersucht mit dem Ziel ein Verhaltensmodell (driving policy) basierend auf einer möglichst kleinen Menge an Annahmen zu lernen. Insbesondere war lediglich vorgegeben, dass das zur erlernende Fahrermodell entlang seiner Route vorankommen will und Kollisionen vermeiden soll, wobei die Verzögerungen, Beschleunigungen und die Lenkwinkeländerungen im Komfortbereich liegen sollen. Alle Aktionen der autonomen Agenten sollen jeweils nur von deren eigenen Beobachtungen der lokalen Umgebung abhängen, d.h. es soll keine explizite Kommunikation zwischen Agenten erfolgen.

Während des Trainings zum Erlernen einer sicheren Interaktion zwischen den Agenten, beispielsweise der Vorfahrtsregeln, wird für alle Agenten mittels gleicher Modellparameter (parameter sharing) ein gemeinsames Fahrermodell und Verhaltensmodell trainiert. D.h. alle Fahrzeuge werden durch das gleiche gelernte Verhaltensmodell (driving policy) gesteuert und die aggregierten Erfahrungen werden genutzt, um diese driving policy kontinuierlich zu verbessern. Das Prinzip des Parameter Sharings wird ferner flankiert durch den effizienten Soft Actor Critic (SAC) Algorithmus während des Trainings zu Anpassung der Rewards. In der Evaluation des Ansatzes wurde insbesondere der Einfluss variierender Verkehrsdichten im Kreisverkehr untersucht.

Abbildung 53 zeigt eine Draufsicht auf den untersuchten Kreisverkehr, der auf realen Geometrien basiert. Für diesen Kreisverkehr wurden sowohl reale Bewegungsmuster aus extrahierten Interaktionen aus Drohnenaufnahmen als initiale Startzustände genutzt als auch synthetisch generierte variierende Verkehrsdichten. Abbildung 54 zeigt die Architektur des Simulationsaufbaus.

Und in Abbildung 55 ist das Ergebnis der simulierten Interaktion für einen Prognosehorizont von 8 Sek. dargestellt. Es wird gezeigt, wie das Fahrermodell und das Verhaltensmodell eine geeignete Lücke zum Einfädeln zwischen 2 Fahrzeugen in den Kreisverkehr abpasst.




Abbildung 53: Vogelperspektive des trainierten Kreisverkehrszenarios in der Ausgabe unserer Simulation. Das Ziel dieser Untersuchung war es ein Fahrverhalten (driving policy) auf Basis abstrakter Fahrvorgaben zu lernen, um damit sicher durch den Kreisverkehr zu fahren, und dies insbesondere auch bei hoher Verkehrsdichte

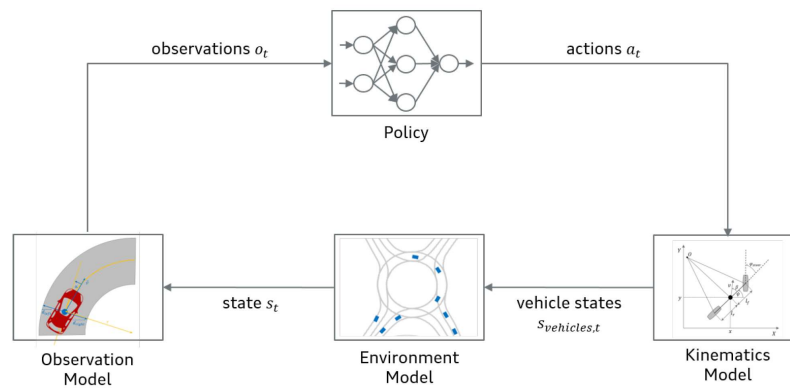


Abbildung 54: Architektur des Simulations-Frameworks: Darstellung des Ablaufs zur Generierung von Aktionen, Aktualisierung der Fahrzeugzustände und Aktualisierung der lokalen Beobachtung auf Basis des Umfeldmodells als Eingang in das Verhaltensmodell




Abbildung 55: Folge von Momentaufnahmen einer Test-Episode, in der in BLAU der betrachtete Agent sich dem Kreisverkehr nähert und eine geeignete Lücke zwischen den anderen Verkehrsteilnehmern abpasst. Alle Fahrzeuge nutzen eine Kopie (Modell plus Parameter) desselben Verhaltensmodells (shared driving policy)

Als nächsten Ansatz zur Verhaltensmodellierung von Fahrzeugen wurde ein neues Verfahren entwickelt, das Verhaltensstrategien auf Basis von Reinforcement Learning, genauer Proximal Policy Optimization, lernt. Die erlernten Fahrstrategien können anschließend angewendet werden, um das Verhalten anderer Verkehrsteilnehmer vorherzusagen oder zu simulieren. Der Fokus der Arbeit lag auf dem Ausdruck unterschiedlicher Fahrertypen, z.B. unterschiedlicher Vorlieben für Querbeschleunigungen oder gewünschte Zeitlücken. Ferner wurde in der Arbeit die Wichtigkeit des Einbezugs von Kooperation an der Einfahrt zum Kreisverkehr untersucht. Details können in nachfolgendem Paper nachgelesen werden: **“Modeling Driver Behavior using Adversarial Inverse Reinforcement Learning”** (M. Sackmann, H. Bey, U. Hofmann, and J. Thielecke) in IEEE Intelligent Vehicles Symposium, 2022.

Unser Doktorand Moritz Sackmann ist gerade noch dabei die gesammelten Erkenntnisse, welche auch in den aufgeführten Veröffentlichungen bereits beschrieben sind, im Rahmen seiner Dissertation zusammenzuschreiben. Vermutlich wird diese im Jahr 2023 veröffentlicht werden.

1.2. TP2 – Digitale Karte und Lokalisation (KL)

Die seitens Audi im Teilprojekt „*Digitale Karte und Lokalisation*“ erzielten Ergebnisse bauen auf den Arbeiten aus dem Förderprojekt *Ko-HAF (Kooperative – Hochautomatisierte Fahrfunktionen)* auf. Die AUDI AG war im TP2 an allen drei Arbeitspaketen beteiligt.

Das Teilprojekt hatte nachfolgende Projektstruktur:

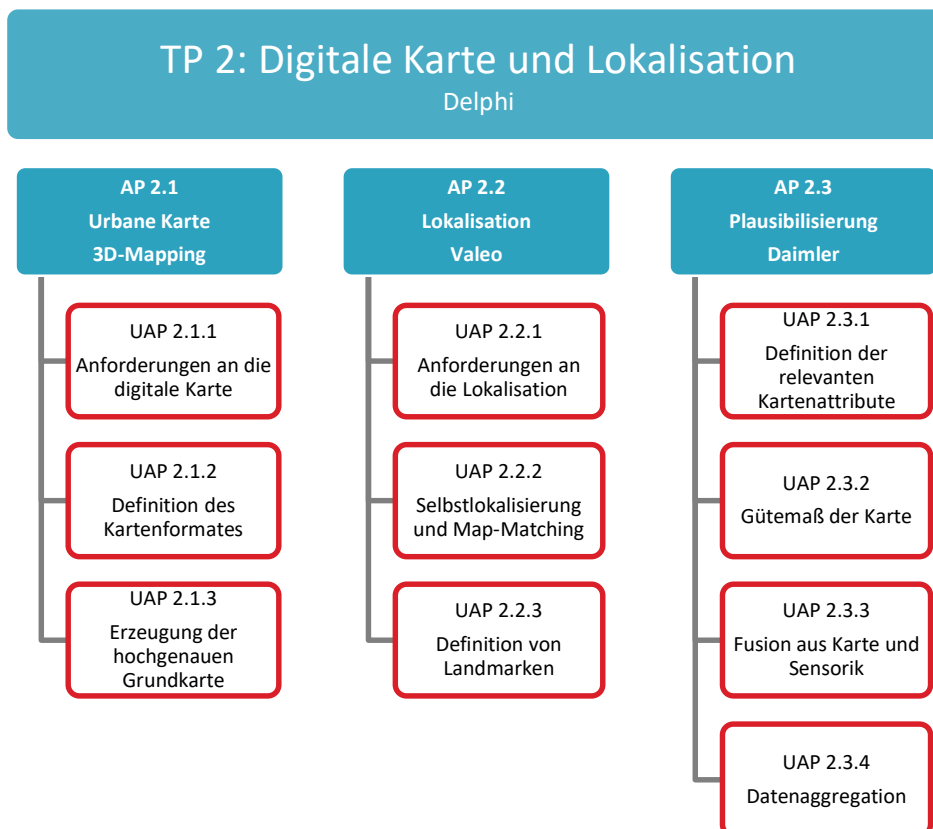


Abbildung 56: Struktur von TP2 „*Digitale Karte und Lokalisierung*“

1.2.1. AP2.1 – Digitale Karte

Im Arbeitspaket AP 2.1 *Urbane Karte* wurde ein gemeinsamer Unterauftrag an den Projektpartner 3D Mapping vergeben, um spezifische Strecken zu vermessen und diese als hochgenaue, digitale HD-Karte (High Density – Karte) zur weiteren Nutzung im Projekt zur Verfügung zu stellen. Die so erstellten HD-Karten dienten als Ausgangsbasis für die Entwicklungen in AP 2.2 *Lokalisation* und AP2.3 *Plausibilisierung*.

Um die Anforderungen an die Inhalte der Karte bzw. an das zu verwendende Kartenformat festzulegen, wurden einige Projekttreffen abgehalten. Diese Treffen fanden noch vor den Einschränkungen durch die Corona-Pandemie statt, so dass diese als Vor-Ort-Treffen stattfinden konnten, was eine schnelle Bearbeitung der



Agendapunkte des Treffens ermöglichte. Pro Partner wurden Teststrecken definiert, welche dann vermessen und als digitale Karte zur Verfügung gestellt wurden.

Der Schwerpunkt Arbeiten der AUDI AG in diesem Arbeitspakt lag auf den Unterarbeitspaketen UAP 2.1.1 *Anforderungen an die digitale Karte* und UAP2.1.2 *Definition des Kartenformats*. Im UAP2.1.3 *Erzeugung der hochgenauen Grundkarte* war Audi nur als „Abnehmer“ der digitalen Karte beteiligt. In diesem Unterarbeitspaket fand Vermessung der Strecke und die Erstellung der HD-Karte durch 3D Mapping statt.

Im Juni 2019 wurde die von Audi definierte „Prio“-Strecke von 3D Mapping vermessen und im OpenDRIVE-Format konvertiert. Bei der „Prio“-Strecke handelt es sich um den ersten kleineren Teil der von der AUDI AG definierten Strecke im Raum Ingolstadt.

Die HD-Karte wurde seitens 3D Mapping als digitale Karte im OpenDRIVE-Format zur Verfügung gestellt. Als Ergebnis des UAP2.1.2 *Definition des Kartenformats* einigten sich alle beteiligten Partner auf das OpenDRIVE-Format, da es für jeden zugänglich ist und somit sowohl von Industrie- als auch von Hochschulpartnern genutzt werden kann. Beim OpenDRIVE-Format handelt es sich um ein sehr detailliertes Kartenformat, welches vom ASAM e.V. released wird.

Zur Validierung der von 3D Mapping gelieferten HD-Karte im OpenDRIVE-Format wurden sowohl hochgenaue Luftbilder des Bundesamtes für Kartographie herangezogen (vgl. Abbildung 57) als auch mit einer Flugdrohne aufgenommene NADIR Bilderserien verwendet. In Abbildung 57 sieht man ein Bild der relativen Höhen im Bereich des hochgenauen 3D Modells. Dies wurde genutzt, um das gelieferte Kartenmaterial zu verifizieren. Im Vergleich zu den Orthofotos des Bundesamtes für Kartographie lassen sich so auch vertikale Strukturen hochgenau lokalisieren (siehe Abbildung 58).

Im Jahr 2021 wurde seitens 3D Mapping das restliche Kartenmaterial geliefert und die Arbeiten seitens Audi am AP2.1 konnten im Wesentlichen abgeschlossen. Kleinere Arbeiten fanden nur noch im Zuge der Vorbereitung der @CITY-Abschlusspräsentation in Aldenhoven statt. Es wurde Feedback für die Gestaltung der @CITY-Fläche auf dem Testgelände gegeben, wodurch eine StVO-konforme Beschilderung umgesetzt werden konnte. Auch wurde hier wieder die von Projektpartner 3D Mapping gelieferten Kartendaten mithilfe von Kamera-basierten 3D Modellen validiert. Abbildung 59 zeigt ein mittels Drohne aufgenommenes hochgenaues 3D-Modell der Teststrecke zum Zeitpunkt der ersten @CITY-Messkampagne auf dem ATC Aldenhoven. Auch wurde von der AUDI AG noch anhand von Satelliten-Bildern das Oval des Testgeländes kartiert, damit die Fahrfunktion im kompletten Demo-Betrieb automatisiert betrieben werden konnte und keine Reinitialisierung vor dem Beginn einer Fahrt nötig ist.




Abbildung 57: Zur Bewertung sowohl der zur Verfügung gestellten Karte als auch der Perzeption des Fahrzeugs wurde auf einem Teil der @CITY Prio-Strecke Ingolstadt mittels eines kamerabasierten 3D Modells vertikale Strukturen extrahiert.




Abbildung 58: Live-Überlagerung eines Ausschnitts der HD-Karte "@CITY Prio-Strecke Ingolstadt" mit einem hochgenauen Orthofoto




Abbildung 59: Mittels Drohne aufgenommenes hochgenaues 3D Modell der Teststrecke zum Zeitpunkt der ersten @CITY Messkampagne im ATC Aldenhoven

Da es sich beim OpenDRIVE-Kartenformat zwar um ein allgemein zugängliches aber für einen Serieneinsatz zu komplexes Kartenformat handelt, haben einige Projektpartner entschieden, ein weiteres, serientauglicheres Kartenformat als Alternative OpenDRIVE zu nutzen. Man hat sich für das PROTOBUF-Format entschieden, welches z.B. bei HD-Karten aus dem Hause HERE zum Einsatz kommt. Zusammen mit dem FORWISS-Institut der Universität Passau, welches im Unterauftrag einiger @CITY-Partner fungiert, wurde die Konvertierung der OpenDRIVE-Karte ins PROTOBUF-Format durchgeführt. Seitens des FORWISS-Instituts konnte auf Vorarbeiten aus dem Förderprojekt *Ko-HAF* zurückgegriffen werden, wo ebenfalls OpenDRIVE-Karten in PROTOBUF-Karten konvertiert wurden. Als Basis diente die oben erwähnte OpenDRIVE-Karte der Prio-Strecke. Die PROTOBUF-Karte ist Grundlage für die weitere Nutzung z.B. für die Fragestellungen der urbanen Lokalisation.

1.2.2. AP2.2 – Lokalisierung

Seitens Audi wurde hinsichtlich der Anforderungen an Landmarken zunächst eine grobe Auflistung von potentiellen Landmarken (LM) erstellt, welche für die Lokalisation gegenüber der digitalen Karte in Frage kommen (z.B. Schilder, Haltelinien, Zebrastrifen, Markierungslinien, Bordsteinverläufe, Leitpfosten, Ampeln, Bäume, Kanaldeckel, Häuserecken, Strukturen etc.). Diese LM-Spezifikation wurde zusammen mit den TP2-Partnern diskutiert. Als Erweiterung wurden wahrnehmungsspezifische Attribute für Landmarken definiert, um diese auch zur a-priori Plausibilisierung von digitalen Karten nutzen zu können. So sind Linien spezifische Merkmale, die zum überwiegenden Teil per Videosensorik detektiert werden können. Vertikale Strukturen wie Häuserkanten, Leitpfosten, Säulen etc. werden am besten per Laser erkannt und zur Erkennung von Standzielen sind Radarsensoren prädestiniert.

Um all diese Informationen (Merkmale) im Sinne einer Lokalisation miteinander zu verbinden, wurde seitens Audi das Konzept einer statischen Umfeldfusion entwickelt. Ergebnis dieser Fusion ist ein statisch fusioniertes Umfeldmodell (STFU), sowie es in Abbildung 60 dargestellt ist.

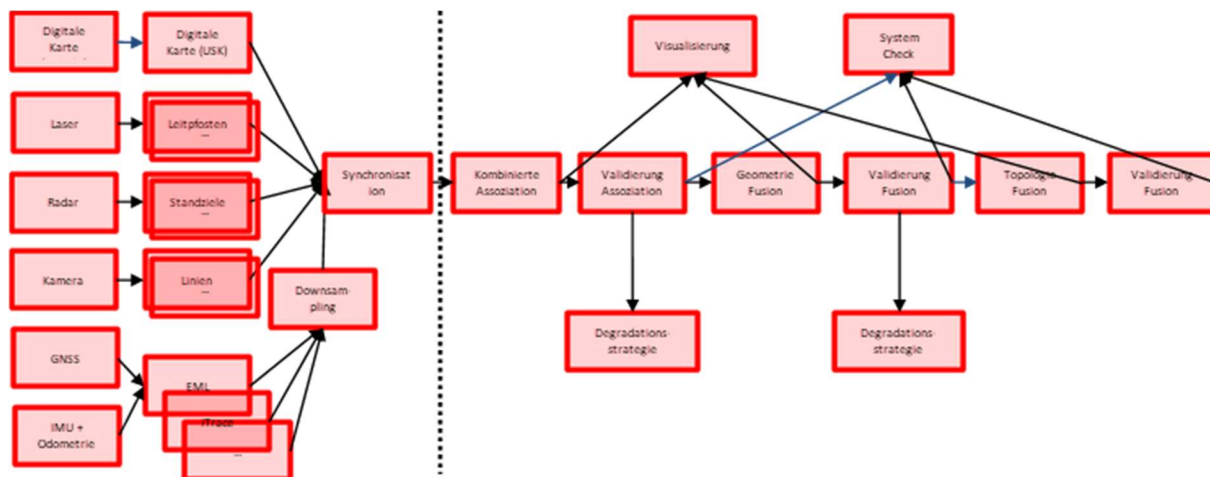


Abbildung 60: Schematische Darstellung des statischen fusionierten Umfeldmodells (STFU)

Nachdem im ersten Halbjahr 2020 der Fokus darauf lag Landmarken-Detektionsergebnisse aus der Kamera in der Fusion zu verwenden und hier spezielle für den urbanen Raum entwickelter klassischer Bildverarbeitungsalgorithmen aus der Kamera genutzt wurden, wurden diese Arbeiten im zweiten Halbjahr 2020 finalisiert und ihr Einfluss auf die Performance des Lokalisierungs-Ergebnisses in der HD-Karte von 3D Mapping bewertet. Weiterhin wurde im zweiten Halbjahr ein Detektor auf Basis einer neuronalen-Netz-basierten Bildsegmentierung angebunden und in der Fusion integriert.

Im Sinne der Umsetzung der statischen Umfeldfusion (Lokalisierungsfusion) wurde Leitpfosten-Detektor des im Fahrzeug integrierten Front-Laser-Scanners angepasst, um alle vertikalen freistehenden Strukturen geringen Ausmaßes ("Poles") zu detektieren. Es werden somit nicht nur hohe Masten oder Verkehrsschilder für die Lokalisierung detektiert, sondern auch kleiner punktförmige Objekte wie etwa Poller. Der aufgrund der steigenden Anzahl an Detektionsergebnissen anspruchsvollere Abgleich mit der digitalen Karte wird mit Hilfe eines A*-Algorithmus' gelöst.

Zur weiteren Plausibilisierung des Lokalisierungs-Ergebnisses wurden auch Standziele aus dem Radar angebunden. Hierbei wurden neben den Long-Range-Radaren nach vorne und hinten auch Eckradar auf 24 GHz-Basis verwendet, die, um ein besseres Sichtfeld zur erreichen, auf dem Dach der Erprobungsfahrzeuge montiert waren.

Ein erster Stand der Lokalisierungsfusion wurde bei der @CITY-Halbzeitpräsentation im November 2020 gezeigt (Abbildung 61). Im rechten Teil des Bildes sind mit roten Kreuzen und Linien die Informationen aus der digitalen Karte hinterlegt. Die rosa-farbenen Punkte sind Lasermessungen und die blauen Kreuze Detektionen der Radarsensoren.

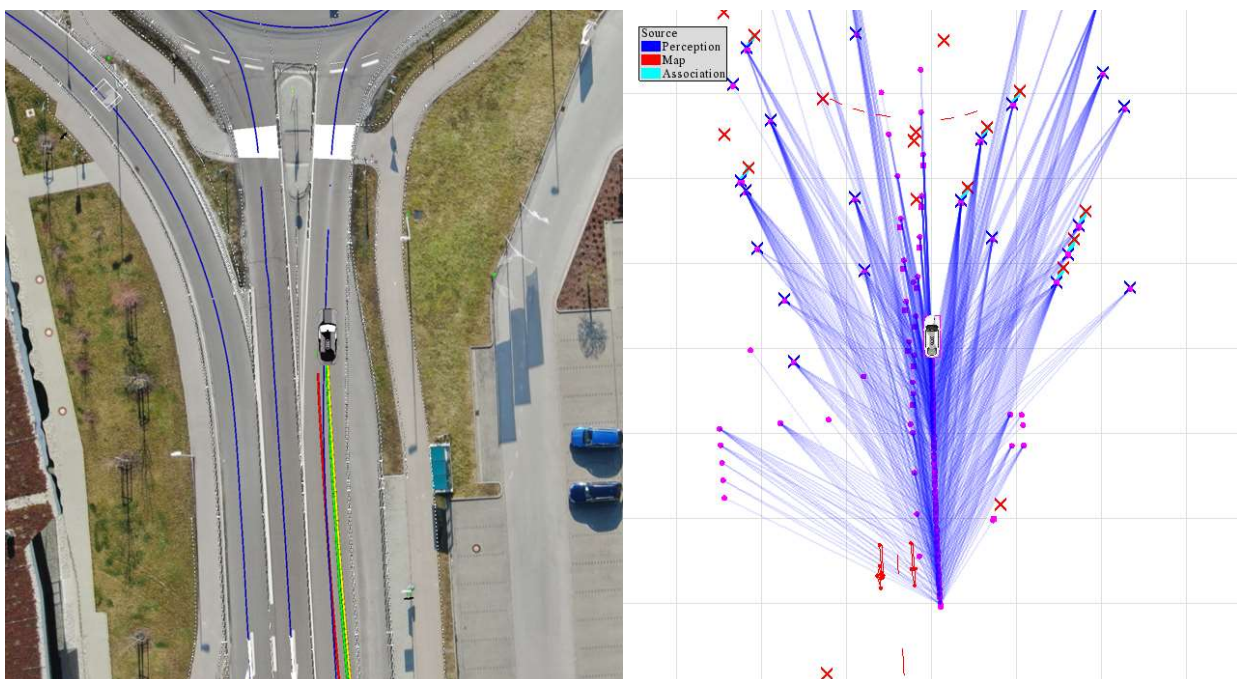


Abbildung 61: Darstellung von Lokalisierung und internem Zustand. Landmarken aus HD-Karte werden erfasst mit Laser, Kamera und Radar

Die Erfahrungen mit diesem Stand auf der Ingolstädter „Prio-Strecke“ wurden auf Seiten der AUDI AG konsolidiert und es wurde gezeigt, dass für die beste Lokalisierungsperformance mit den @CITY-Karten und den verbauten und angebundenen Sensoren eine Fusion aus GNSS, vertikale Strukturen geringen Durchmessers aus den Serien-Laserscannern und Fahrbahnmarkierungen aus den neuronalen Netzen der Bildverarbeitung die beste Lokalisierungs-Genauigkeit erreicht und für eine robuste Lokalisierung auf den vorhandenen Kartendaten ausreicht.



Die hohe Anzahl an Detektionen aus der Sensorik und die hohe Anzahl an Landmarken in der Karte haben eine neue und komplexere Algorithmik zur Korrespondenz-Findung nötig gemacht, so dass als nächster Schritt eine kombinierte Assoziation und Validierung der Assoziation der hauptsächliche Fokus der AUDI AG im Rahmen des AP 2.2 war.

Der schlussendlich implementierte Algorithmus arbeitet in 3 Schritten. Im ersten Schritt werden die aus der Umfeldwahrnehmung detektierten Landmarken eigenbewegungskompensiert in eine lokale Karte eingetragen. Diese werden geclustert und für jeden Cluster wird dann eine Landmarkenhypothese gebildet. Dieser Schritt wird im Folgenden "Lokale Assoziation" genannt.

Im nächsten Schritt werden aus der a-priori HD-Karte Landmarken-Kandidaten über eine Umfeldsuche der aktuellen Positions-Schätzung extrahiert. Der Umkreis wird hier recht groß gewählt, so dass die Genauigkeit der Eingangs-Positionsschätzung gering sein kann und für diese Initialisierung auch nur ein handelsübliches GPS reicht. Die Landmarkenhypothesen werden jetzt als Ganzes versucht so auf den a-priori-Kartenausschnitt zu legen, dass es möglichst viele Korrespondenzen gibt und der Gesamtfehler möglichst gering ist. Dieser Schritt wird im Folgenden "Map Matching" genannt.

Im dritten und letzten Schritt werden diese Korrespondenzen dann genutzt, um zusammen mit der Eigenbewegungsschätzung mithilfe einer großen Ausgleichsrechnung die Fahrzeugposen innerhalb eines gewissen Zeitfensters und die tatsächlichen Positionen der beobachteten Landmarken zu bestimmen. Die Positionen der Landmarken aus der a-priori Karte dienen hier als Initialschätzung für die Landmarken-Positionen. Dieser Schritt wird im Folgenden "Optimierung" genannt. Als eine der wichtigsten Eingangsgrößen für diesen Algorithmus dient die Eigenbewegungsschätzung. Hierfür wird eine Kalman-Filter basierte Sensordatenfusion genutzt, welche aus den Wegimpulsgebern des Fahrzeugs, der serienmäßig verbauten 6-DOF (6-DegreesOfFreedom) Inertial-Mess-Einheit und einem auch in Serienfahrzeugen genutzten GNSS Receiver die Position in einem sogenannten "Klemme 15"-Koordinatensystem bestimmt. Das Koordinatensystem wird so genannt, weil es zum Zeitpunkt des Zündungsgangs (also des Startens des Fahrzeugs, bzw. einem damit korrespondierenden Signal auf "Klemme 15") auf 0 initialisiert wird. Um die Bewegung des Fahrzeugs zwischen zwei Zeitpunkten zu ermitteln, werden die Positionen im "Klemme 15"-Koordinatensystem voneinander abgezogen.

Der GNSS Receiver liefert hier hauptsächlich Korrekturen für den im allgemeinen nur annähernd bekannten Reifenumfang. Als Startwert für die Reifenumfangsschätzung wird der mittlere Reifenumfang aller über die Typengenehmigung zugelassen Reifengrößen genommen. Aber auch für Korrekturen mancher Start-Offsets und Linearen Fehlerkomponenten der Inertial-Messeinheiten werden die GNSS Messdaten verwendet.

Bei der lokalen Assoziation für Poles aus dem Laser und für Linien-Merkmalen aus der Kamera muss unterschiedlich vorgegangen werden. Beim Laser ist es über die bekannte extrinsische Kalibrierung des Sensors möglich die detektierten Landmarken



recht einfach in die lokale Assoziations-Ebene umzurechnen, da man aus dem Laser direkt Entfernung und Winkel misst. Dies ergibt einen Punkt in Sensorkoordinaten, der dann über die bekannte Einbaulage des Sensors auf einen lokalen karosseriefesten Bezugspunkt umgerechnet werden kann. Für diesen karosseriefesten Bezugspunkt wird auch die bereits erwähnte Eigenbewegungsschätzung durchgeführt und damit ist hier die Position in der lokalen Assoziations-Ebene bekannt. In der Regel wird die lokale Assoziations-Ebene bei Start des Moduls einmal festgelegt und bleibt dann fest. Die so in die lokale Assoziations-Ebene eingetragenen Beobachtungen sind bewegungs-kompensiert. D.h. liegt der Detektion ein statisches Umgebungsmerkmal zugrunde sollten sich über die Zeit die Beobachtungen örtlich Häufen. Über ein räumliches Clustern in der Assoziations-Ebene können jetzt über Statistiken die Güte der Detektionen beurteilt werden und auch über einen Schätzer und ein den Messungen zugrunde liegendes Fehlermodell/Beobachtungsmodell die wahre Position der Landmarken in der lokalen Assoziations-Ebene bestimmt werden.

Dies kompensiert Ungenauigkeiten in den Messungen und macht das Modul robust gegenüber Ausreißern.

Bei der lokalen Assoziation für die Detektionen in der Kamera wird im aktuellen Stand ein vereinfachtes Modell angewendet. Hauptproblem bei Bild-Daten ist, dass zwar die Winkel der Beobachtungen sehr genau sind, jedoch die Entfernung unbekannt ist. Um die Features trotzdem in einer lokalen Assoziations-Ebene aggregieren zu können, werden diese über eine Ebene-Welt-Annahme in die Ebene projiziert. D.h. es wird davon ausgegangen, dass die Sichtstrahlen, welche im Kamerabild für die Detektion von Spurmarkierungen verantwortlich sind, von einer durch die lokale Aufstandsfläche des Fahrzeugs definierten Ebene ausgegangen sind.

Beim nächsten Schritt, dem MapMatching, haben wir einen der Hauptvorteile des Verfahrens. Es wird hier nämlich kein Greedy-Verfahren für das Map-Matching angewendet, sondern die relativen Positionen der Landmarken zueinander in der lokalen Assoziations-Ebene als fest angenommen und dann geschaut durch welche globale Verschiebung der Assoziations-Ebene die Landmarkenkandidaten in der Karte am besten abgedeckt werden. Hierbei wird ein RANSAC ähnliches Verfahren angewendet. Ziel ist es nicht eine möglichst genaue Abdeckung zu bekommen, sondern Fehllassoziationen möglichst zu vermeiden. Fehllassoziationen sind Fehlerhafte Zuordnungen zwischen Landmarkenhypothesen aus Detektionen der Umfeldwahrnehmung und den Landmarkenkandidaten aus der a-priori Karte. Diese würden im nächsten Schritt der Optimierung zu sehr schlechten Ergebnissen, da hier mit Normalverteilungsannahmen gearbeitet wird und der verwendete Optimierungsalgorithmus daher anfällig ist für Ausreißer.

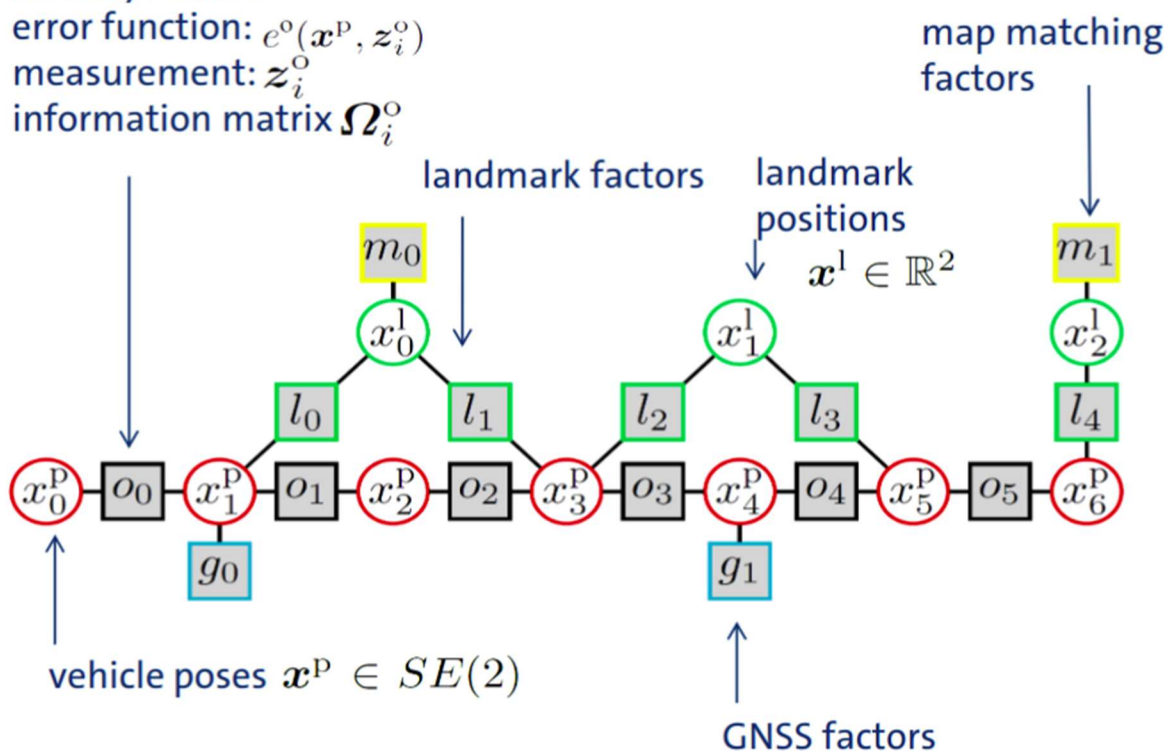
In dem letzten Schritt, der Optimierung wird dann über ein Zeitintervall von mehreren Sekunden mithilfe der Eigenbewegungsschätzung ein geometrischer Zusammenhang zwischen den zu den Detektionen gehörenden Sensor-Messgrößen, den jeweiligen Fahrzeugposen und den a-priori bekannten geo-referenzierten Positionen der Landmarken hergestellt. In Abbildung 62 sieht man eine schematische Darstellung der Modellierung. Über eine Regression werden damit simultan die Fahrzeugposen in diesem Zeitintervall und die Landmarken-Positionen ermittelt, welche am besten zu den Detektionen passen. Dieses Optimierungsverfahren funktioniert natürlich nur dann

gut, wenn genügend Landmarkenbeobachtungen vorliegen. Ein Zeitintervall von 10 Sekunden hat bisher in den meisten Fällen ausgereicht, um eine robuste Lokalisierung zu ermöglichen. Da sich die Fehler der Eigenbewegungsschätzung in dem Zeitintervall aufakkumulieren erhöht sich mit einem größeren Fenster die Ungenauigkeit der Positionsschätzung. Es ist also eine Abwägung zwischen Genauigkeit und Robustheit zu treffen. Ist das Zeitfenster zu klein, können sich die Sensormessfehler nicht mehr effektiv herausmitteln und Bereiche ohne Landmarken-Detektionen können nicht mehr so gut überbrückt werden. So ist auch in diese Richtung eine Abwägung zu treffen.

Factor Graph

odometry factor:

- error function: $e^o(\mathbf{x}^p, \mathbf{z}_i^o)$
- measurement: \mathbf{z}_i^o
- information matrix Ω_i^o



○ Nodes → Optimizable States

□ Factors

Abbildung 62: Schematische Darstellung der Modellierung für das Optimierungsproblem

In Abbildung 63 und Abbildung 64 sieht man den Lokalisierungsgraph mit den Kartendaten und der aktuellen Fahrzeugpose. Blau: Kandidaten für Poles aus der Karte; Grün: Detektionen; Gelb: Fahrzeugposen. Der Übersichtlichkeit wurden hier keine Linien-Assoziationen visualisiert.




Abbildung 63: Visualisierung des Lokalisierungs-Graphs auf Teststrecke in Aldenhoven




Abbildung 64: Zoom auf Lokalisierungsgraph

Ergebnisse zur Landmarken-basierten Lokalisation von der Teststrecke in Aldenhoven sieht man in Abbildung 65. Der translatorische Fehler (Querversatz) liegt bei unter 20 cm, mit einem Ausreißer über den Zeitraum der Messung, wo ein maximaler Fehler von 30 cm auftritt.




Abbildung 65: Performance Lokalisierung mit Pfosten als Landmarken auf der wahrscheinlichen Demo-Strecke

Mit der implementierten Landmarken-basierten Lokalisation wird sogar eine bessere Lokalisierungsgüte erreicht, als ein Standard GNSS RTK-System erreicht. Mit einer Standardabweichung von 4,6 cm liegt man unter der für RTK-Systeme vorgegebenen Spezifikation von 6 cm. Die in Abbildung 66 dargestellte Statistik unterstreicht die Performance, der in @CITY entwickelten Landmarken-basierten Lokalisation.

translation error [m]	
count	1699.000000
mean	0.081373
std	0.046143
min	0.007000
50%	0.071600
68%	0.098064
97%	0.181818
99%	0.225740
max	0.262800

Abbildung 66: Statistik des Lokalisierungsfehlers bei einer Lokalisation mit Pfosten auf der Demo-Strecke; Spezifikation des GNSS RTK Systems von 6cm StdAbweichung wird erreicht und in dieser Messung sogar unterboten.

1.2.3. AP2.3 – Plausibilisierung

Im zweiten Halbjahr 2020 wurde bei der AUDI AG im Arbeitspaket 2.3 *Plausibilisierung* erste Grundlagen für eine quantitative Bewertung der eigenen Lokalisierungsfusion gelegt. Dabei wurden software-technischen Anpassungen vorgenommen, um möglichst viele Maßzahlen zur Bewertung der Fusion, Wahrnehmung und HD-Karte ausleiten zu können. Dies ermöglichte im Weiteren mit den bisher konzeptuell



erarbeiteten und in der Simulation getesteten Gütemaßen Erfahrung zu sammeln (vergleiche auch Abbildung 57)

Für das UAP 2.3.2 wurden Integritäts- und Gütemaße erarbeitet, welche es ermöglichen sollen, eine gerade aktualisierte digitale Karte mittels sensorischer Umfeld erfassung und unter Berücksichtigung der Messunsicherheiten und Lokalisationsfehler zu bewerten, noch bevor die Karteninhalte zur Verbesserung des Situationsverständnisses und der Verkehrsführung und zur Erweiterung der Vorausschau genutzt werden. Ferner soll untersucht werden, anhand welcher Kriterien/Gütemaße der Plausibilisierung von einzelnen Merkmalen und Inhalten auf die Konsistenz größerer Teile einer Karte geschlossen werden kann. Die Plausibilisierung der Karte mittels sensorisch erfasster Umfeldmerkmale erfolgt auf mehreren Ebenen nach einer einfachen Strategie. Zunächst wird auf Basis von Landmarken und Linienverläufen mittels Bündelausgleich das beste Matching zur Lokalisation gegenüber der digitalen Karte ermittelt und die Lokalisationsunsicherheit bestimmt. Dann wird über eine Verdeckungsanalyse bestimmt, welche Inhalte der digitalen Karte hinsichtlich der Sichtbereiche der Sensoren und Verdeckungen durch dynamische Verkehrsteilnehmer gerade sichtbar bzw. verdeckt sind. Für die prinzipiell sichtbaren Landmarken wird überprüft, ob diese durch die sensorische Wahrnehmung innerhalb eines Zeitfensters bestätigt worden sind und wie gut die geometrischen Zuordnungen zwischen Pfosten oder Linienverläufen an den Stützstellen der Modellbeschreibungen waren. Hierbei wird bei Verfügbarkeit auch die semantische Klasse mit überprüft (z.B. durchgezogene Linien, gestrichelte Linie, weiße/gelbe Linie, Bordstein). Fehlende Zuordnungen oder große Abweichungen weisen hierbei auf eine entsprechende Diskrepanz zwischen Karte und sensorischer Wahrnehmung hin. Die Identifikation einer signifikanten Diskrepanz oder aber auch die Bestätigung einer großen Übereinstimmung ohne relevante Widersprüche ist hierbei bereits ein wesentlicher Fortschritt.

Das entwickelte System zur Plausibilisierung von linienförmigen Landmarken und zur live-Analyse von Karten-Plausibilitäten bekommt aus der Wahrnehmung über die Zeit verfolgte Landmarken und assoziiert diese mit a-priori-Daten aus der Karte. Dazu wird ein Joint-compatibility-branch-and-bound (JCBB) Algorithmus verwendet. Die Assoziationen und die zugehörigen Fehler-Metriken zur Güte der Übereinstimmung werden über die Zeit aggregiert. Diese Daten bilden dann die Basis anhand derer die erarbeiteten Plausibilitätsmaße berechnet werden.

Nachfolgend sieht man eine Folge von Abbildungen des Assoziierungsschritts (Abbildung 67), den Zustand der Plausibilisierung nachdem man einige Meter auf dem Testgelände gefahren ist (Abbildung 68) und zur Gegenüberstellung noch den Zustand ohne aggregierte Historie (Abbildung 69).

Legende:

Roter Pfeil: Fahrzeugposition

Rot: Linien aus der Karte

(Verschiedene semantische Klassen haben verschiedene Farbtöne)

Blau: aktuelle getrackte Linien

(Gestrichelte und durchgezogene Linien haben verschiedene Farbtöne)

Grüne Querverbindungen: Assoziationen zwischen aktuellen getrackten und Kartenlinien

(Farbton gibt Güte der Übereinstimmung an)

Grün entlang der Kartenlinien: Plausibilisierte Elemente

(Farbton gibt Güte der besten Übereinstimmung an)

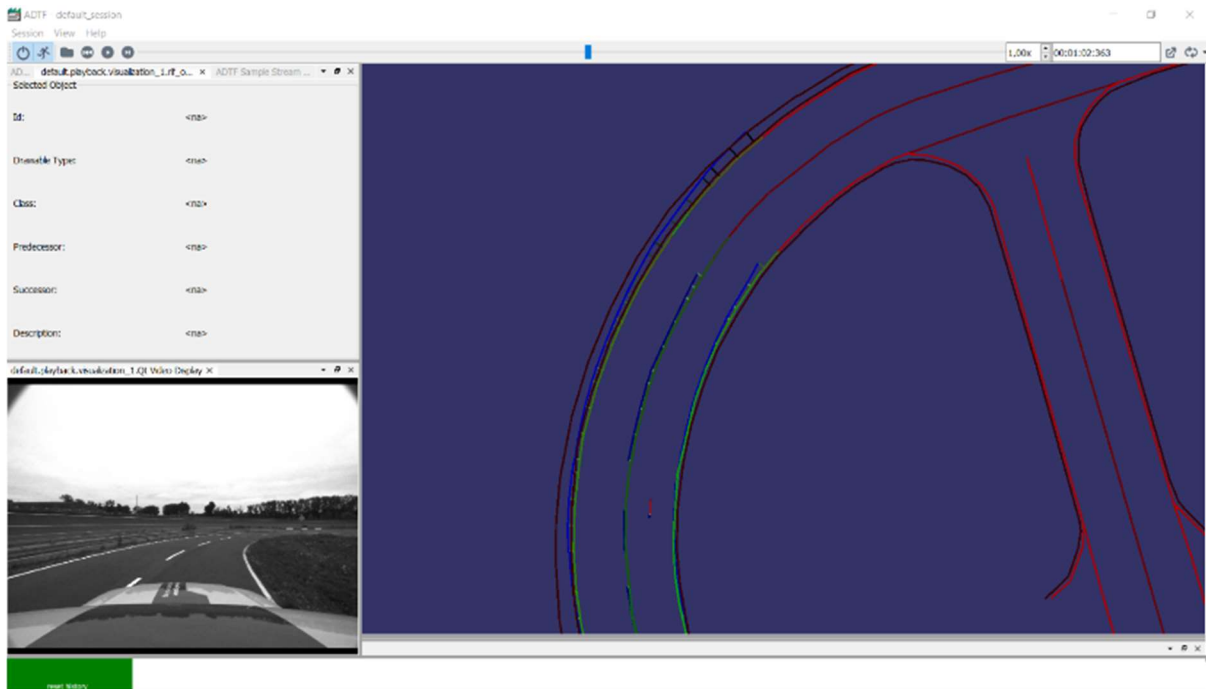


Abbildung 67: Plausibilisierung linienförmiger Landmarken: Assoziation (Aktueller Schritt)

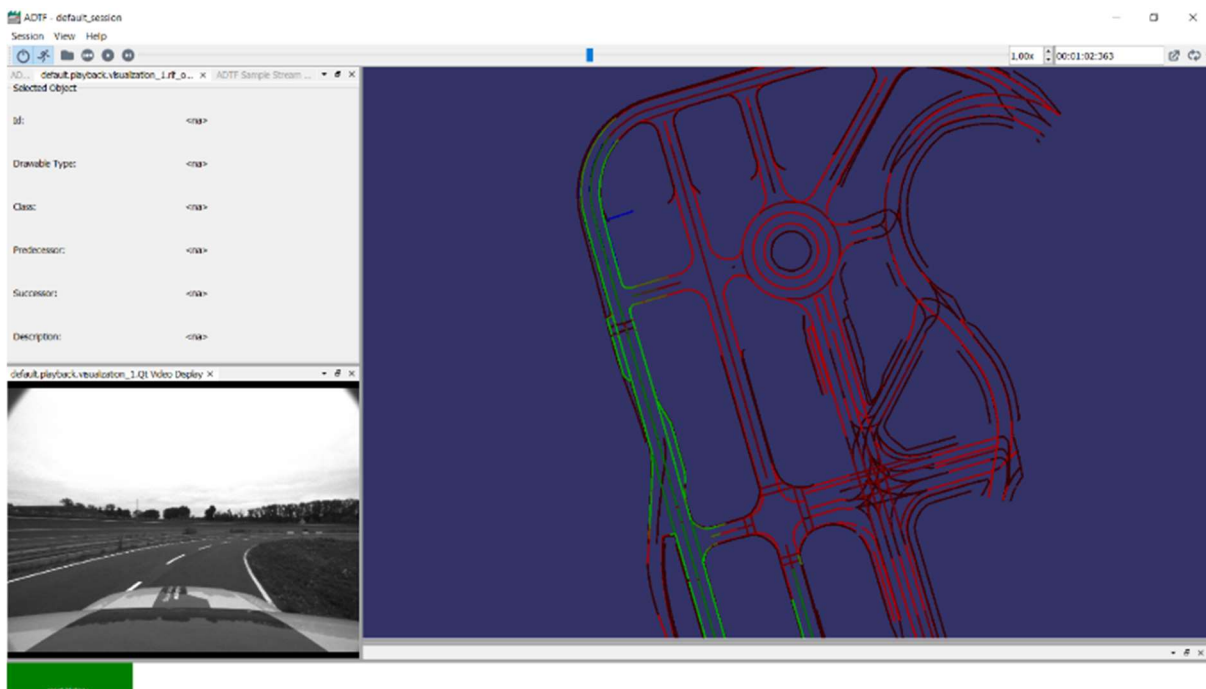


Abbildung 68: Plausibilisierung linienförmiger Landmarken (Inklusive Historie)

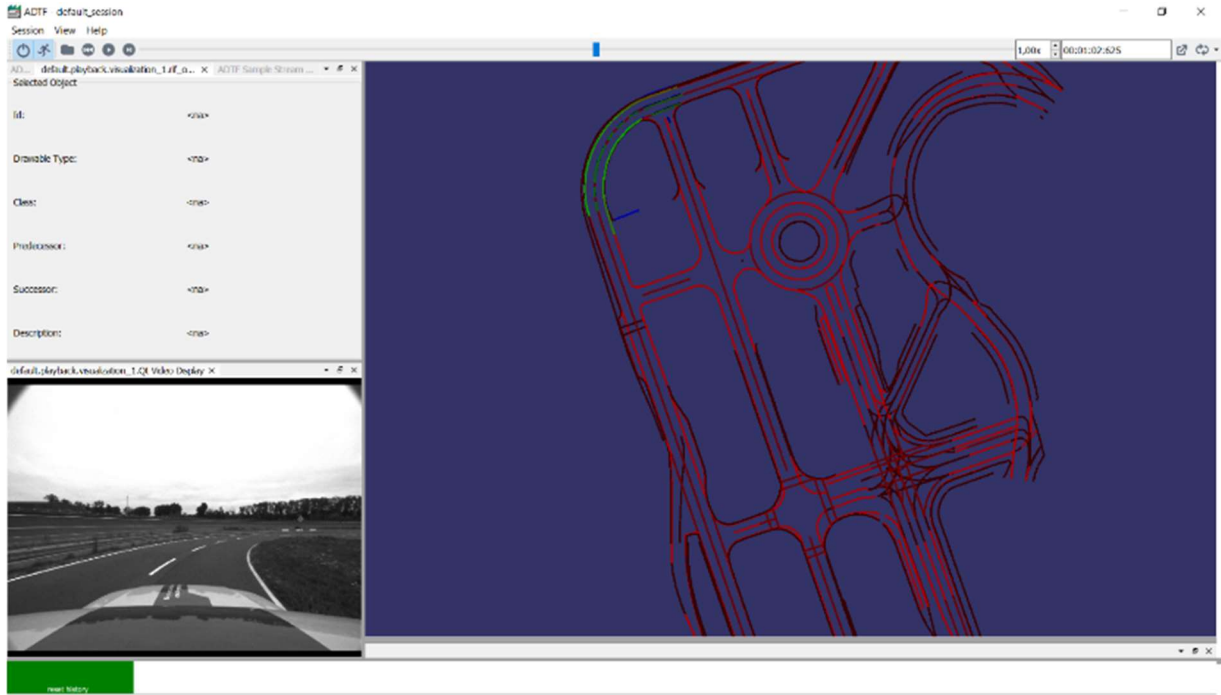


Abbildung 69: Plausibilisierung linienförmiger Landmarken: Nach dem Verwerfen der Historie (Reset)

1.3. TP3 – Konzepte und Pilotanwendungen (KP)

Das Teilprojekt KP (*Konzepte und Pilotanwendungen*) besteht aus zwei Schwerpunkten. Zum einen soll für das gesamte @CITYProjekt eine Beschreibungsmöglichkeit für Szenarien und zur Funktionsbeschreibung gefunden werden, mittels derer sämtliche an @CITY-Beteiligte ihre Anforderungen formulieren und ableiten können. Zum anderen sollen in einer zweiten Phase exemplarisch einige Pilotanwendungen prototypisch umgesetzt werden. Angedacht sind hier prototypische Umsetzungen des Use Cases „dynamische Engstelle“ mit folgenden Szenarien auf innerstädtischen Verbindungsstrecken (Abbildung 70):

- *Umgang mit Radfahrern.* Diese erschweren das Vorbeifahren (insbesondere, wenn sie beabsichtigen, links abzubiegen). Das automatisierte Auto muss auf die Radfahrer warten oder ein vorsichtiges Überholmanöver planen und durchführen.
- *Parkende Fahrzeuge in 2. Reihe* oder Fahrzeuge, die sich gerade im Ausparkvorgang befinden. Auch hier ist entweder auf diese Verkehrsteilnehmer zu warten oder ein Vorbeifahren zu planen und automatisiert durchzuführen.



Abbildung 70: Prototypisch in @CITY umzusetzende Pilotanwendungen

Zur Bearbeitung der genannten Umfänge hatte das Teilprojekt folgende Projektstruktur.

TP 3: Konzepte und Pilotanwendungen

Valeo

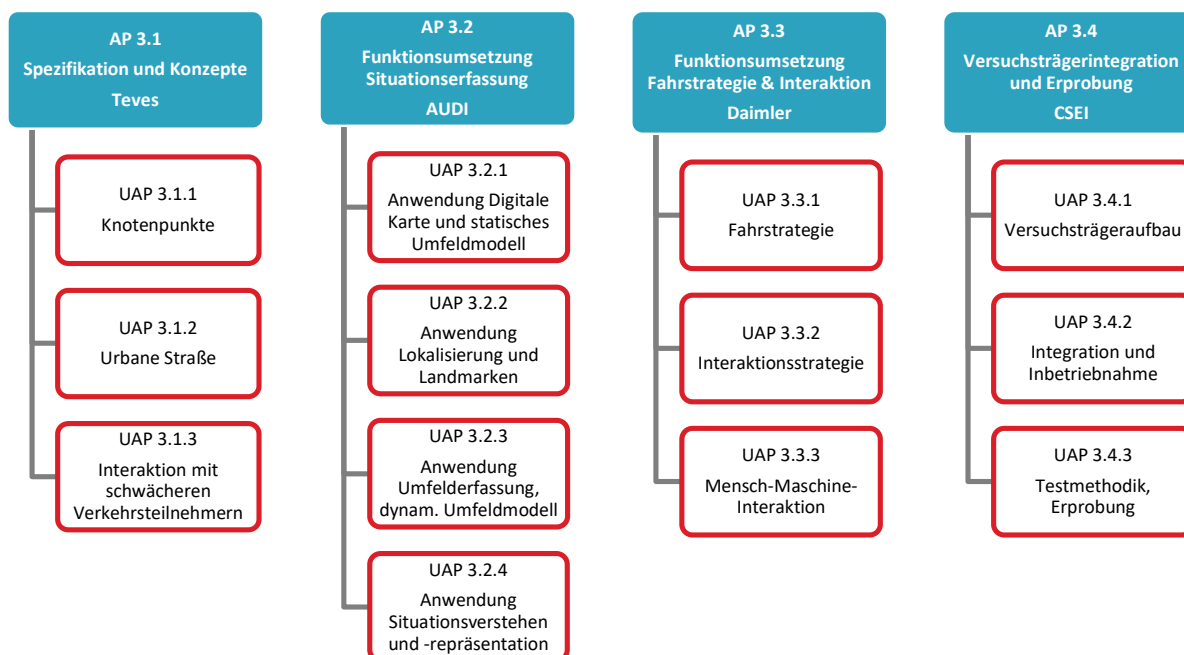


Abbildung 71: Struktur von TP3 „Konzepte und Pilotanwendungen“

1.3.1. AP3.1 – Spezifikation und Konzepte

Für eine durchgängige Entwicklung neuer automatisierter Fahrfunktionen aber auch für das nachfolgende Testen und Absichern ist eine formalisierte Beschreibung von Szenarien aber auch des Sollverhaltens der gewünschten automatisierten Fahrfunktion notwendig. Eine derartige formale Beschreibung ist ein wichtiges Ergebnis des Förderprojekts @CITY, das zum einen während des Projektverlaufs in den anderen Teilprojekten zur Anwendung kam. Zum anderen ist die formale Beschreibung für weitere Arbeiten im Bereich des automatisierten Fahrens eine wichtige Grundlage.

Audi hat als Abprungbasis die Szenarienbeschreibungen aus den vorausgegangenen Förderprojekten wie *UR:BAN* oder *PEGASUS* eingebracht. Die Szenarienbeschreibung aus *PEGASUS* ist diesbezüglich am weitesten vorangeschritten und verwendet als Basis die OpenX-Formate OpenDRIVE, zur Repräsentation des stationären Umfelds, und OpenSCENARIO zur Beschreibung dynamischer Objekte wie anderen Fahrzeugen, Fußgängern etc. in diesem stationären Umfeld. Allerdings muss festgehalten werden, dass Szenarien ausschließlich für den Testfall beschrieben werden. Es ist daher nicht vorgesehen, dass Sollverhalten einer automatischen Fahrfunktion zu beschreiben. Dies wird implizit vorausgesetzt, muss als für den Anwendungsfall in @CITY ergänzt werden.

Innerhalb *PEGASUS* werden Szenarien durch unterschiedliche Inhalte beschrieben, die sich wie die folgende Abbildung 72 zeigt, zusammensetzen.



Abbildung 72: Inhaltlicher Aufbau von Szenarien

Die Bezeichnung der unterschiedlichen Inhalte durch Level von L1 bis L5 ist allerdings irreführend, da diese leicht mit den Automatisierungs-Level gemäß SAE verwechselt werden können. An dieser Stelle muss noch präzisiert werden.

Quintessenz dieser Darstellung ist jedoch, dass Szenarien aus unterschiedlichen Inhalten bestehen, die gemäß dieser Darstellung strukturiert werden können.

Neben dieser Beschreibung der Inhalte von Szenarien werden in *PEGASUS* zusätzlich Abstraktionsstufen von Szenarien definiert (siehe Abbildung 73).

Funktionale Szenarien	Logische Szenarien	Konkrete Szenarien
<p><u>Basisstrecke:</u> 3-streifige Autobahn in Kurve Begrenzung auf 100 km/h durch Verkehrszeichen rechts und links</p>	<p><u>Basisstrecke:</u> Breite Fahrstreifen [2,3..3,5] m Kurvenradius [0,6..0,9] km Pos_Verkehrszeichen[0..200] m</p>	<p><u>Basisstrecke:</u> Breite Fahrstreifen [3,2] m Kurvenradius [0,7] km Pos_Verkehrszeichen [150] m</p>
<p><u>Stationäre Objekte:</u> -</p>	<p><u>Stationäre Objekte:</u> -</p>	<p><u>Stationäre Objekte:</u> -</p>
<p><u>Bewegliche Objekte:</u> Ego, Stau; Interaktion: Ego in Manöver „Annähern“ auf mittlerem Fahrstreifen, Stau zähfließend</p>	<p><u>Bewegliche Objekte:</u> Stauende_Pos [10..200] m Stau_Geschw. [0..30] km/h Ego_Abstand [50..300] m Ego_Geschw. [80..130] km/h</p>	<p><u>Bewegliche Objekte:</u> Stauende_Pos 40 m Stau_Geschw. 30 km/h Ego_Abstand 200 m Ego_Geschw. 100 km/h</p>
<p><u>Umwelt:</u> Sommer, Regen</p>	<p><u>Umwelt:</u> Temperatur [10..40] °C Tröpfchengröße [20..100] µm</p>	<p><u>Umwelt:</u> Temperatur 20 °C Tröpfchengröße 30 µm</p>

Abbildung 73: Abstraktion von Szenarien

Abbildung 74 stellt die Abstraktionslevels gemäß der Definition aus dem Förderprojekt etwas anders dar.

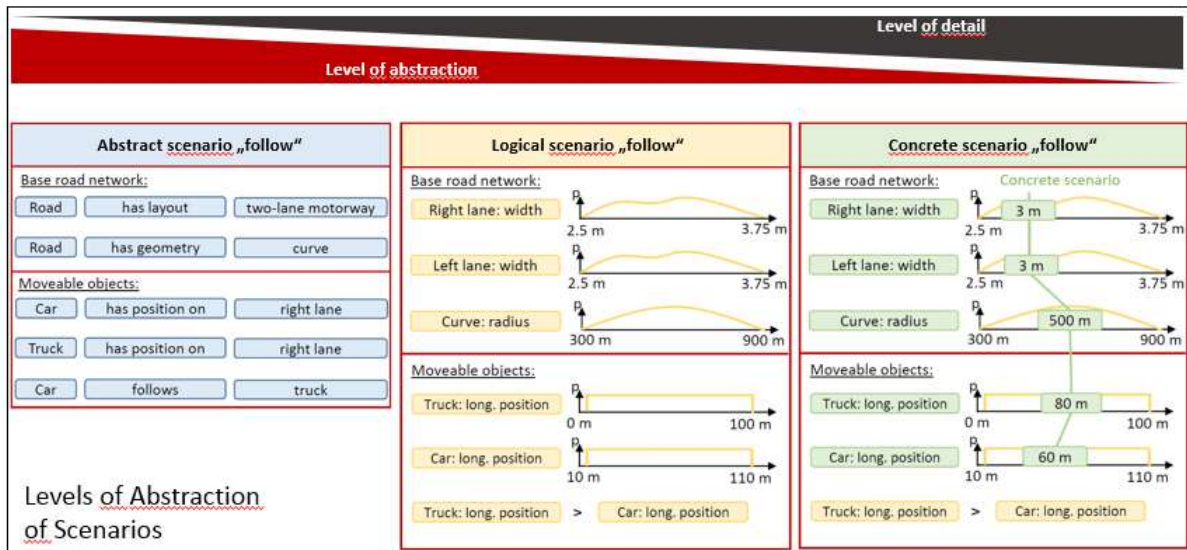


Abbildung 74: Abstraktionslevels von Szenarien

Für die unterschiedlichen Detaillierungsstufen von Szenarien wurden in *PEGASUS* folgende Beschreibungen erarbeitet:

Konkretes Szenario

Ein konkretes Szenario stellt ein parametrisiertes Modell mit festen Parametern der zeitlichen Abfolge von Szenen (logisches Szenario) dar, welches mit einer konkreten Startszene beginnt.

Alle Parameter, die ein Verkehrsereignis beschreiben, sind im konkreten Szenario explizit festgelegt. Zu einem Zeitpunkt findet genau ein Konkretes Szenario statt.

Logisches Szenario

Ein Logisches Szenario stellt eine formale Beschreibung von Szenarien dar. Entitäten und Beziehungen unter diesen sind parametrisch formuliert. Bereiche für die Parameter sind formuliert. Beziehungen zwischen Parameterbereichen können angegeben sein. Auf Basis der Logischen Szenarien werden konkrete Szenarien abgeleitet.

Abstraktes Szenario

In einem Abstrakten Szenario sind die Entitäten und deren Beziehungen untereinander formuliert. Abstrakte Szenarien werden sprachlich gefasst. Das Vokabular kann für den Anwendungsfall spezifisch sein. Die Formulierung ist widerspruchsfrei. Entsprechend Anwendungsfall kann die Detaillierung unterschiedlich sein.

Aufbauend auf den Ergebnissen aus PEGASUS wurde im Rahmen dieses Teilprojekts ein Exzelliste erstellt, welche sich hinsichtlich der Einteilung in einzelne Rubriken an der Nomenklatur zur Szenarienbeschreibung des Förderprojekts PEGASUS orientiert. Auf der obersten Ebene wird in eine statische und eine dynamische Beschreibung unterschieden.

Situationsbeschreibung - Statisch																						
Entwurfselemente	Dimensionierung	Straßentyp(en)	Einschränkung(en) und Straßendeckschicht und Fahrbahnzustand			Verkehrssteuerung und -regeln	Konfliktfläche	Objekte und Landmarken	VRU-Infrastruktur	VRU-"Hot Spots"												
			Merkmale	Sichtbarkei(en)	Beschreibung der statischen (Materialien) der untersuchten Fahrbahnen und Wege, sowie der vorliegende Zustand und Qualität der Fahrbahn und der						Bestandteile (Materialien) der untersuchten Fahrbahnen und Wege, sowie der vorliegende Zustand und Qualität der Fahrbahn und der	Aufzählung sämtlicher Verkehrsregeln und falls vorhanden Lichtsignalanlage n (LSA);										
Generelle Dimensionierung der Entwurfselemente nach > Art > Grundform > Räumlicher Ausschnitt > sichtbare Bereiche	Dimensionierung der Entwurfselemente nach > Dimensionierung FGSV > Relevante Abschnitte und Verkehrsregeln > Spur des gewählten Fahrmanövers > (Relevante) Markierungen > Führung von FG, RF, SW und RAE	Definition des Straßentyps mit besonderen Merkmalen, insbesondere der Fahrmannöver	Angabe über die Führung von Elementen für die Durchführung von Fahrmannövern	Beschreibung der statischen (Materialien) der untersuchten Fahrbahnen und Wege, sowie der vorliegende Zustand und Qualität der Fahrbahn und der	Beschreibung der statischen (Materialien) der untersuchten Fahrbahnen und Wege, sowie der vorliegende Zustand und Qualität der Fahrbahn und der	Aufzählung sämtlicher Verkehrsregeln und falls vorhanden Lichtsignalanlage n (LSA);	Abgeleitete Merkmale aus der Entwurfselementgestaltung (räumlicher Ausschnitt): > Konfliktpunkte > Konfliktfläche > Schnittpunkte und -flächen mit Rad- und Fußgängerwegen, Busspuren, Straßenbahnen	Aufzählung sämtlicher Objekte und Landmarken in der Form [ID, Name, Geometrie, Geometrieklasse, Textur, Sem. Verknüpfung, Bezug zu relevanten Entwurfselementen (ID, Spezifikation)]	VRU-Infrastruktur (gemeinsam oder getrennt) > relative Höhe zur Fahrbahnoberfläche (auf Fahrbahn oder auf Bürgersteig) > Breite > Abstand zum Fahrstreifen > bauliche Trennung > Winkel zum Fahrstreifen > mit LSA gesteuert	VRU-"Hot Spots" > Haltestellen > Supermarkt > Schule > Kindergarten												
Statische Situation - Dimensionierung																						
<table border="1"> <thead> <tr> <th>Merkmale</th> <th>Dimensionierung der Entwurfselemente</th> <th>Relevante Abschnitte und Verkehrsregeln</th> <th>Spur des gewählten Fahrmanövers</th> <th>(Relevante) Markierungen</th> <th>Führung von Fußgängern FG, Radfahrern RF, Sonderwegen SW und Rechtsabgrenzungselementen RAE</th> </tr> </thead> <tbody> <tr> <td> Erkäuterung: Von rechts nach links: Entzerrung der Verbindungsstraßenfahrbahnen V2 bis V6, der Bürgersteige B1 bis Bn, der Fahrradwege F1 bis Fn, der Parkwege P1 bis Pn und sonstiger Wege S1 bis Sn, jeweilige Angabe der Geländehöhe, Lage (Ausrichtung) und Größe (Länge, Breite, Kurvenradius, etc.) </td> <td> > V1: 184 m, 20', [100m, 3m, 0, S-Form] > V2: 184 m, 20', [100m, 3m, 0, S-Form] > V3: -9 m, 0', [33m, 2,5m, 10m, L-Form] </td> <td> [P2-Vorfahrt] achten > [V3-Vorfahrtsstraße/abgesichertes Hindernis auf rechtem Fahrbahnrand] > [V4-Vorfahrtsstraße/einstellige Begrenzung der </td> <td> [V3:10m > V3_4,5m > V4:15m > V4_3,5m > V3-NaWi] </td> <td> *Parkreihe ist mit gestrichelter Linie versehen > einseitige Begrenzung der Fahrbahn V4 </td> <td> > B1 und B6 knüpfen direkt an die Parkspur P2 und P5. Der Bürgersteig hat eine Bordsteinkante von 10 cm Höhe. > Fußgängerüberweg/Fahrbahnen von B1 nach B6 über P2, V3, V4 und P5 </td> </tr> </tbody> </table>											Merkmale	Dimensionierung der Entwurfselemente	Relevante Abschnitte und Verkehrsregeln	Spur des gewählten Fahrmanövers	(Relevante) Markierungen	Führung von Fußgängern FG, Radfahrern RF, Sonderwegen SW und Rechtsabgrenzungselementen RAE	Erkäuterung: Von rechts nach links: Entzerrung der Verbindungsstraßenfahrbahnen V2 bis V6, der Bürgersteige B1 bis Bn, der Fahrradwege F1 bis Fn, der Parkwege P1 bis Pn und sonstiger Wege S1 bis Sn, jeweilige Angabe der Geländehöhe, Lage (Ausrichtung) und Größe (Länge, Breite, Kurvenradius, etc.)	> V1: 184 m, 20', [100m, 3m, 0, S-Form] > V2: 184 m, 20', [100m, 3m, 0, S-Form] > V3: -9 m, 0', [33m, 2,5m, 10m, L-Form]	[P2-Vorfahrt] achten > [V3-Vorfahrtsstraße/abgesichertes Hindernis auf rechtem Fahrbahnrand] > [V4-Vorfahrtsstraße/einstellige Begrenzung der	[V3:10m > V3_4,5m > V4:15m > V4_3,5m > V3-NaWi]	*Parkreihe ist mit gestrichelter Linie versehen > einseitige Begrenzung der Fahrbahn V4	> B1 und B6 knüpfen direkt an die Parkspur P2 und P5. Der Bürgersteig hat eine Bordsteinkante von 10 cm Höhe. > Fußgängerüberweg/Fahrbahnen von B1 nach B6 über P2, V3, V4 und P5
Merkmale	Dimensionierung der Entwurfselemente	Relevante Abschnitte und Verkehrsregeln	Spur des gewählten Fahrmanövers	(Relevante) Markierungen	Führung von Fußgängern FG, Radfahrern RF, Sonderwegen SW und Rechtsabgrenzungselementen RAE																	
Erkäuterung: Von rechts nach links: Entzerrung der Verbindungsstraßenfahrbahnen V2 bis V6, der Bürgersteige B1 bis Bn, der Fahrradwege F1 bis Fn, der Parkwege P1 bis Pn und sonstiger Wege S1 bis Sn, jeweilige Angabe der Geländehöhe, Lage (Ausrichtung) und Größe (Länge, Breite, Kurvenradius, etc.)	> V1: 184 m, 20', [100m, 3m, 0, S-Form] > V2: 184 m, 20', [100m, 3m, 0, S-Form] > V3: -9 m, 0', [33m, 2,5m, 10m, L-Form]	[P2-Vorfahrt] achten > [V3-Vorfahrtsstraße/abgesichertes Hindernis auf rechtem Fahrbahnrand] > [V4-Vorfahrtsstraße/einstellige Begrenzung der	[V3:10m > V3_4,5m > V4:15m > V4_3,5m > V3-NaWi]	*Parkreihe ist mit gestrichelter Linie versehen > einseitige Begrenzung der Fahrbahn V4	> B1 und B6 knüpfen direkt an die Parkspur P2 und P5. Der Bürgersteig hat eine Bordsteinkante von 10 cm Höhe. > Fußgängerüberweg/Fahrbahnen von B1 nach B6 über P2, V3, V4 und P5																	

Abbildung 75: Statische Szenarienbeschreibung am Beispiel einer Engstelle

In Abbildung 75 ist eine statische Szenarienbeschreibung am Beispiel einer Engstelle dargestellt. Die Szenarienbeschreibung erfolgt anhand von Merkmalen und Attributen. Merkmale sind Entwurfselemente, Straßentypen, usw. Die Entwurfselemente, Dimensionierung, sowie die Objekte und Landmarken bestehen aus weiteren Sub-Merkmalen die in gesonderten Tabellenblättern beschrieben werden (roter Kasten innerhalb Abbildung 75).

Ergänzend zur statischen Szenarienbeschreibung wurden in analoger Weise Elemente der dynamischen Szenerie als Erweiterung der Excel-Tabelle hinterlegt. Abbildung 76 zeigt den Teil der Excel-Tabelle, der die dynamischen Szenarienbeschreibung umfasst. Auch hier wurden Detaillierungen einzelner Merkmale in gesonderten Tabellenblättern aufgelistet, die in Abbildung 76 ebenfalls durch einen roten Rahmen hervorgehoben sind.

Um ein derartiges Soll-Verhalten zu beschreiben, wurde entschieden, dass Soll-Verhalten mit einem Phasenmodell zu beschreiben (siehe Abbildung 77). Das Phasenmodell dient zum einen als Grundlage zur Beschreibung der Anforderungen an die Umfeldwahrnehmung. In Abbildung 10 ist das Phasenmodell für das Szenario „Ausweichmanöver mit kooperierendem Gegenverkehr“ zu sehen, welches eine Detaillierung des Phasenmodells aus Abbildung 77 ist und für welches exemplarisch die Ableitung von Anforderungen für die Umfeldwahrnehmung in AP1.1 durchgeführt wurde.

Aus dem Phasenmodell können Ablaufdiagramme (Abbildung 9) abgeleitet werden, die wiederum in eine formale Sprache wie z.B. Gherkin-Files überführt werden können. Es ist somit gewährleistet, dass auch das Soll-Verhalten formal beschrieben ist. Für die Funktionsumsetzung, für die Beschreibung der Fahrstrategie ist somit auch ein formaler Rahmen geschaffen.




Abbildung 77: Phasenmodell für die Vorbeifahrt an einem stehenden Hindernis

Mit den bisher beschriebenen Konzepten und Methoden wurde ein Rahmen geschaffen, der die inhaltliche Umsetzung von urbanen Fahrfunktionen unterstützt. Diese Grundlagen standen im Folgenden nicht nur für die weitere Bearbeitung innerhalb der Teilprojekte aus @CITY sondern auch für die Bearbeitung der Teilprojekte des Schwesterprojekts @CITY-AF zur Verfügung. Innerhalb des Projekts @CITY wurde die formale Beschreibung von Szenarien und des Sollverhaltens bereits im TP1 *Umfelderfassung und Situationsverstehen* für die Festlegung der Anforderungen an ein urbanes Sensorset. Die in AP3.1 erzielten Ergebnisse sind aber auch Grundlage für die weiteren Arbeitspakete innerhalb des TP3 *Konzepte und Pilotanwendungen*.

Wie zu Beginn von Abschnitt 1.3 motiviert, wurde in den folgenden Arbeitspaketen des TP3 auf ein paar wenige Pilotanwendungen fokussiert und diese prototypisch umgesetzt. Es handelte sich dabei um Use Cases aus dem Umfeld von dynamischen Engstellen. Seitens der AUDI AG wurde an der Pilotanwendung „Passieren einer Bushaltestelle“ quasi einem „Zweite Reihe Parker“-Szenario gearbeitet.

1.3.2. AP3.2 – Funktionsumsetzung Situationserfassung

Seitens der AUDI AG wurden die Inhalte des Themenfelds *Funktionsumsetzung Situationserfassung* mit seinen spezifischen Unterarbeitspaketen *Anwendung digitale Karte und statisches Umfeldmodell* (UAP3.2.1) sowie *Anwendung Lokalisierung und Landmarken* (UAP3.2.2) im TP2 *Digitale Karte und Lokalisierung* sowie die Umfänge zur *Anwendung Umfelderkennung und dynamisches Umfeldmodell* (UAP3.2.3) sowie *Anwendung Situationsverstehen und Situationsrepräsentation* (UAP3.2.4) in den Unterarbeitspaketen im TP1 *Umfelderfassung und Situationsverstehen* bearbeitet. Dies umfasste sowohl die methodische Bearbeitung als auch eine prototypische Implementierung. Bei der Bearbeitung standen Szenarien wie die „Dynamische Engstelle“ aus TP3 als auch weitere Szenarien aus dem Schwesterprojekt @CITY-AF wie urbane Knotenpunkte oder Szenarien auf urbanen Verbindungsstrecken im Fokus.

An dieser Stelle wird daher auf Spezifika eingegangen, welche sich auf die Pilotanwendung „Dynamische Engstelle“ beziehen. Da dieses Szenario, welches von der AUDI AG bearbeitet wurde, vor den Szenarien aus @CITY-AF feststand, wurde die Auslegung eines für den urbanen Raum tauglichen Sensorsets mit diesem Szenario begonnen.

Audi hat sich für die Umsetzung eines urbanen Sensorsets entschieden, drei unterschiedliche Sensorprinzipien zu verwenden. Das Sensorset besteht daher aus Radar-, Kamera- und Lasersensoren. Deren Einbaulagen sind in Abbildung 78, Abbildung 79 und Abbildung 80 zu sehen.

> Kamera





Abbildung 78: Konzept Einbaulagen von Kamerasensoren

> Lasersysteme



Legende:

Seriensystem



360° Fusion System




3D Laser



Abbildung 79: 360° Laserfusionssystem mit optionalem 3D-bildgebendem Laser im Frontbereich

> Radar



Legende:

Mid Range Radar



Long Range Radar



Nahbereichsradar



Option



Abbildung 80: Konzept für Radarbasierte Umfelderkennung bestehend aus 3 Sensorgruppen

Das Sensorset soll möglichst alle urbanen Szenarien abdecken, wie sie im TP3 des Förderprojekts @CITY aber auch in den Teilprojekten TP5 und TP6 des Förderprojekts @CITY-AF von Audi bearbeitet wurden. An dieser Stelle sei auf den Abschlussbericht der AUDI AG zum Förderprojekt @CITY-AF verwiesen.

Anhand von Schlüsselszenarien wurde das Sensorset und die Erkennung der für die Fahrfunktion relevanten Informationen validiert. Zu den Schlüsselszenarien zählen z.B. Anfahrt auf Kreisverkehr, Anfahrt ab Haltelinie an Kreisverkehren und Kreuzungen, Erkennung LSA an Haltelinie, Erkennung anderer Verkehrsteilnehmer an Kreuzung, Überholen bei Zweite-Reihe-Parkern, Erkennung und Verfolgung von Bussen in Bushaltestellen etc..

Die Validierung des Sensorkonzeptes erfolgte dabei mit Hilfe einer Erweiterung der vorhandenen Simulationsumgebung namens Sensorsketcher, welche die visuelle Bewertung von Sichtbereichen und Auflösungen von Sensoren für funktionsrelevante Szenarien ermöglicht. Abbildung 81 zeigt exemplarisch einen Blick von oben (Birds-Eye-View) auf das Szenario „Bus in Bushaltestelle“, bei dem mittels des Simulationstools Sensorsketcher, die Sichtbereiche der Sensoren visualisiert sind.

Nach erfolgter Validierung des Sensorsets in der Simulation wurde dieses Sensorset zunächst in ein erstes Erprobungsfahrzeug der AUDI AG eingebaut. Als Basisfahrzeug hierfür diente ein Audi Q8. In Abbildung 82 ist das erste Audi Erprobungsfahrzeug mit den verbauten Sensoren zu sehen. Nachdem sich nach kleinen Anpassungen das Sensorset bewährt hat, wurde es auch in zweites Audi Erprobungsfahrzeug integriert.




Abbildung 81: Birdseye-View des Szenarios „Bus in Bushaltestelle“ in der Simulation mit Sensorsketcher




Abbildung 82: Zusatzausstattung (Sensoren, Display) des Audi Erprobungsfahrzeugs

Sämtliche Methoden und Algorithmen zur Erfassung des Umfelds der Pilotanwendung „Dynamische Engstelle“ wurden in den Teilprojekten TP1 und TP2 erarbeitet. Es sei daher auf die Kapitel 1.1 und 1.2 dieses Berichtes verwiesen.

1.3.3. AP3.3 – Funktionsumsetzung Fahrstrategie und Interaktion

Gleiches wie in AP3.2 *Situationsfassung* gilt in viel stärkerem Maße für AP3.3 *Funktionsumsetzung Fahrstrategie und Interaktion*. Da es sich bei den in Abbildung 70 dargestellten Engstellenszenarien um eine Untermenge sämtlicher im urbanen Raum potentiell auftretender Szenarien handelt, wurde für diese Szenarien keine losgelöste Funktionsumsetzung verfolgt, sondern die Aktivitäten wurde in einen übergreifenden Kontext verlagert. Nachdem das Schwesterprojekt @CITY-AF gestartet wurde und dort an den funktionalen Teilprojekte TP5 *Urbane Knotenpunkte*, TP6 *Urbane Straße* und TP7 *Interaktion mit schwächeren Verkehrsteilnehmern* die Arbeiten begonnen wurden, verlagerte sich der Schwerpunkt der Entwicklungsarbeiten im Bereich Fahrstrategie seitens Audi in die Teilprojekte TP5 und TP6, an denen Audi ebenfalls beteiligt war. Für detaillierte Informationen zu den verwendeten Algorithmen und Methoden, zu deren Umsetzung in funktionalen Software-Modulen sei daher auf den Abschlussbericht der AUDI AG für das Förderprojekt @CITY-AF verwiesen.

An dieser Stelle sei auf den allgemeinen Entwicklungsschritt eingegangen, wie die Fahrstrategie, quasi das Sollverhalten abgeleitet werden kann. Als Beispiel hierfür dient das Engstellenszenario „Bus verlässt Bushaltestelle“ gemäß folgender Abbildung 83.



Abbildung 83: Szenario „Bus verlässt Bushaltestelle“

Einem Bus des ÖPNV ist bei Ausfahrt aus einer Bushaltestelle Vorfahrt zu gewähren, so wie dies in Abbildung 83 dargestellt ist. Um von der bisherigen, abstrakten Beschreibung in die Implementierung der Fahrstrategie zu gelangen, wurden sogenannte Konfliktflächen definiert. Deren Grenzen können mit Polynomen beschrieben und einer digitalen Karte als Zusatzinformation verortet werden. Mit den Konfliktflächen ist somit ein geometrisches Konstrukt geschaffen, mit deren Hilfe nicht nur in dem hier beispielhaft verwendeten Szenario „Bus verlässt Bushaltestelle“ sondern allgemein, Flächen definiert werden können, in denen potentiell kritische Situationen auftreten können.

Hierfür ist jedoch ein weiteres funktionales Konstrukt notwendig und zwar die Routeninformation des eigenen Fahrzeugs, welche ebenfalls in der digitalen Karte hinterlegt ist. Die Routeninformation hilft dabei, die störungsfreie Route des automatisierten Fahrzeugs vorherzusagen. Kreuzt die Route eine potentielle Konfliktfläche, so muss das Verhalten des EGO-Fahrzeugs angepasst werden, in dem z.B. die Geschwindigkeit reduziert oder sogar angehalten wird. Da die Überprüfung auf Kreuzen der Fahrzeugtrajektorie mit einer potentiellen Konfliktfläche zyklisch erfolgt, können somit potentielle Konflikte entschärft werden.

Abbildung 84 zeigt eine mögliche Konfliktfläche im dynamischen Engstellenszenario „Bus verlässt Haltestelle“.




Abbildung 84: Konfliktflächen (rot schraffiert) im Szenario „Bus verlässt Bushaltestelle“

Das vorgestellte Konzept zur Umsetzung einer festgelegten Fahrstrategie ist ein Ergebnis aus TP3, das nicht nur für bei den Pilotanwendungen Anwendung findet, sondern so allgemein gehalten ist, dass es auch bei den Fahrfunktionen der Teilprojekte TP5, TP6 und TP7 des Schwesterprojekts @CITY-AF angewendet werden kann.

1.3.4. AP3.4 – Versuchsträgerintegration und Erprobung

Inhalt dieses Arbeitspaketes war es, den Aufbau der @CITY-Erprobungsfahrzeuge zu steuern, die Integration der Funktionssoftware zu ermöglichen und Konzepte fürs Testing zu entwickeln und gemeinsame Erprobungen zu organisieren.

Um den Aufbaustatus der @CITY-Erprobungsfahrzeuge zu dokumentieren, wurde in Anlehnung an das Vorgängerprojekt *UR:BAN* eine Excel-Tabelle für jedes Fahrzeug angelegt, auf Basis derer in regelmäßigen Abständen der Aufbauzustand dokumentiert wurde. Abbildung 85 zeigt den Aufbaustatus des ersten Audi Erprobungsfahrzeugs für das Förderprojekt @CITY. Wie der Tabelle zu entnehmen ist, waren die Arbeiten an den Basiskomponenten (Stromversorgung, Kühlung, Busabgriffe, etc.) zum genannten Zeitpunkt weitgehend abgeschlossen. Zum genannten Zeitpunkt standen noch Arbeit zur Integration der für den urbanen Raum notwendigen Zusatzsensorik und deren Anbindung ans Rechnersystem des Fahrzeugs aus.



	Systeme	Einzelkomponenten	Fortschritt in %	Kommentar
Fahrzeug	atCity Fahrzeug-ID	atCity_1	77%	10.02.2020
	Partner	AUDI AG		
	Partnerspezifische Fahrzeugnummer	Audi_1		
	Fahrzeugtyp	Audi Q8		
	Motorisierung	3.0 TDI		
Grundaufbau	Powermanagement	Ladegerät, Zusatzbatterie, DC/AC-Wandler	100%	
	Zusatzlüftung / Kühlung	zusätzliches Klimagerät	100%	
	Bussysteme	CAN, Flexray, Ethernet	100%	
	Systemschalter	Herkömmliche Bedienelemente + Touchscreen	100%	
	Zusatzkomponenten			
Ansteuerbare Aktorik	Längsaktorik	Bremsbooster, ESC, ECU über ACC-Schnittstelle	100%	
	Queraktorik	EPS	100%	
Ego-Sensorik	Inertialsystem	Serien-Inertialsystem (3x Beschleunigung, 3x Drehrate)	100%	
	Odometriesensoren	4x Raddrehzahlsensoren	100%	
	Fahrwerkssensoren	Höhenstandssensoren	100%	
	Globales Ortungssystem	GPS	100%	
Umfeldsensorik	Erfassungsbereich Front	Long Range Radar, Stereokamera, High-Res Monokamera	50%	
	Erfassungsbereich Seite	Short Range Radar front, 2 x Short Range Radar rear	50%	
	Erfassungsbereich Hinten	Short Range Radar rear	50%	
Kommunikationseinheit	Kommunikationsrechner, LTE-Modem, Antennen	API-Box, Backend agent.	70%	
	SIM-Karten/Vertrag	vorhanden	100%	
Funktionsrechner	CarPC's	1x Fahrzeugserver	70%	
	RP-Hardware (Autobox, ES1000, ...)	s.u.	80%	
	Entwicklungssteuergeräte	modifizierte Steuergeräte für Lenkung, Bremse, etc.	100%	
	Spezialhardware	spezifisches Datenaufzeichnungsgerät	60%	
HMI	HUD	ja	40%	
	Kombidisplay	ja	40%	
	Infotainmentdisplay	ja	40%	
	Zusatzdisplays	Touchscreen zur Visualisierung von Entwicklungsdaten und Bedienung der Systemfunktion	40%	
	Fahrerzustandserkennung	nein		
	LED-Leiste	nein		
	Bedienelement für HAF-Funktion	ja	40%	
Sicherheitssystem	Notaufsystem	nein		
	Not-Aus	ja	100%	

Abbildung 85: Aufbauzustand des ersten Audi Erprobungsfahrzeugs im 2. Halbjahr 2019

Ein weiterer Schwerpunkt das AP3.4 war das Testen der entwickelten Fahrfunktionen. Hierzu gehörte u.a. die Erarbeitung einer Methodik fürs Testing. Ziel der @CITY-Testmethodik ist daher die Erweiterung der Beschreibung vorhandener Testmethoden wie in z.B. aus PEGASUS, Ko-HAF, Enable-S3. Dies ist vorrangig wegen der höheren Komplexität von urbanen Szenarien notwendig. Die Erweiterung des Testkonzepts beinhaltet die Testfallgenerierung (Umfang: Häufigkeit, Kritikalität, ...) basierend auf einem Szenarien- und Situationskatalog, Testdurchführung (z.B. in der Simulation, Testgelände, öffentl. Straßenverkehr) und die Testauswertung (insb. Bewertungskriterien).



Der Focus im @CITY-Projekt liegt auf der Validierung der hochautomatisierten Fahrfunktionen in ausgewählten Szenarien und stellt keine zulassungsrelevante Absicherung dar. Die Validierung fand nur im eingeschränkten Umfeld statt, wo auch HD-Karten vorhanden waren (z.B. öffentliche Testbereiche der Partner, Teststrecken).

Im ersten Schritt wurden die bestehenden Testmethodiken aus den vorausgegangenen Förderprojekten *PEGASUS*, *Ko-HAF* und *Enable-S3* analysiert. Diese Testmethodiken beruhen überwiegend der Beschreibung verhältnismäßig einfacher Szenarien. So sind beispielsweise Autobahnszenarien deutlich berechenbarer in Bezug auf die geringere Dynamik der Verkehrsteilnehmer, der Variation des Umfeldes resultierend in geringeren Anforderungen an die Umfelderkennung und der Handlungsplanung.

Da sich das Förderprojekt @CITY im urbanen Umfeld abspielte, gibt es eine Menge an komplexen Verkehrssituationen, die die Anforderungen an automatisierte Systeme und deren Testing deutlich erhöhen. Hierzu gehören unter anderem:

- Hochgradig dynamische Verkehrsteilnehmer: Fußgänger, Radfahrer oder andere Fortbewegungsmittel wie Roller oder E-Scooter. Diese bewegen im Vergleich zu Fahrzeugen inhomogen und können die Bewegungsrichtung in sehr kurzer Zeit stark wechseln
- Komplexe Kreuzungstopologien mit mehreren (Abbiege)-spuren und komplexen Lichtsignalanlagen
- Komplexe Kreisverkehrstopologien mit mehreren Spuren sowie ggfs. Lichtsignalanlagen und Zebrastreifen
- Dynamische Engstellen verursacht durch parkende Fahrzeuge, Baustellen etc.

Zur Beschreibung der erhöhten Komplexität der Szenarien wurden in @CITY die Nutzung einer Szenarienbeschreibung bestehend aus statischer und dynamischer Situationsbeschreibung aufgesetzt (vgl. AP3.1). Ergänzend zur Szenarienbeschreibung wurde zur Beschreibung des Soll-Verhaltens ein Phasenmodell eingeführt. Abbildung 77 zeigt das Phasenmodell für das Engstellenszenario „Vorbeifahrt an einem stationären Hindernis“. Zeigt die Phasenmodelle für Kreuzungen und Kreisverkehre, so wie sie in AP3.2 erarbeitet wurden.




Abbildung 86: Phasenmodell für Kreuzungen und Kreisverkehre

Aufbauend auf der Szenarienbeschreibung und dem Phasenmodell zu Beschreibung des Soll-Verhaltens wurde eine Testmethodik entwickelt. Abbildung 87 zeigt eine Übersicht der Testmethodik für @CITY. Im Unterschied zu anderen Förderprojekten steht die Integration des Phasenmodells im Vordergrund. In Kombination mit der statischen und dynamischen Situationsbeschreibung resultiert eine spezifische Szenarienbeschreibung (SB) dynamisch/statisch, welche phasenabhängig ist und aus der die Test-Cases abgeleitet werden können. Diese phasenabhängige Struktur hilft zur Beschreibung der hochgradig komplexen und dynamischen Szenarien im urbanen Umfeld.

Auf Basis dieser Testmethodik wurden seitens der AUDI AG Testfälle generiert, die sowohl in der Simulation als auch auf Prüfgeländen abgearbeitet wurden. Das Testen von neuen bzw. verbesserten Funktionsimplementierungen fand zunächst in der Simulation statt, so dass die grundsätzliche Performance der neuen Funktionsmodule gewährleistet war. Es stellt sich aber heraus, dass speziell in komplexen Szenarien wie an Kreisverkehren oder an Kreuzungen es oftmals zu nicht vorhersehbaren Situationen kommt, die dann erst im Nachgang und unter großem Implementierungsaufwand in eine Simulation übertragen werden können. Seitens Audi verschob sich der Fokus daher sukzessive von der Simulation zum Realtest.

Hierzu fanden einige gemeinsame Erprobungen statt. Neben den bilateralen Erprobungen zwischen MAN und Audi, zum Testen des „Bushaltestellen“-Szenarios auf dem Prüfgelände von MAN in München, fanden auch einige projektübergreifende Erprobungen auf dem Aldenhoven Test Center (ATC) statt. Auf dem ATC fand letztendlich auch die @CITY-Abschlusspräsentation statt, um so wichtiger war, es dort intensiv zu testen. So wurden zu folgenden Zeitslots 23.-24.11.2021, 14.-16.03.2022, 13.-14.04.2022, 9.-10.05.2022 und 30.-31.05.2022 dankenswerter Weise vom

@CITY-Projektbüro gemeinsame Testtage organisiert, an denen urbaner Verkehr auf dem Prüfgelände aufgrund der mitgebrachten Erprobungs- und „Hasen“-Fahrzeuge herrschte.

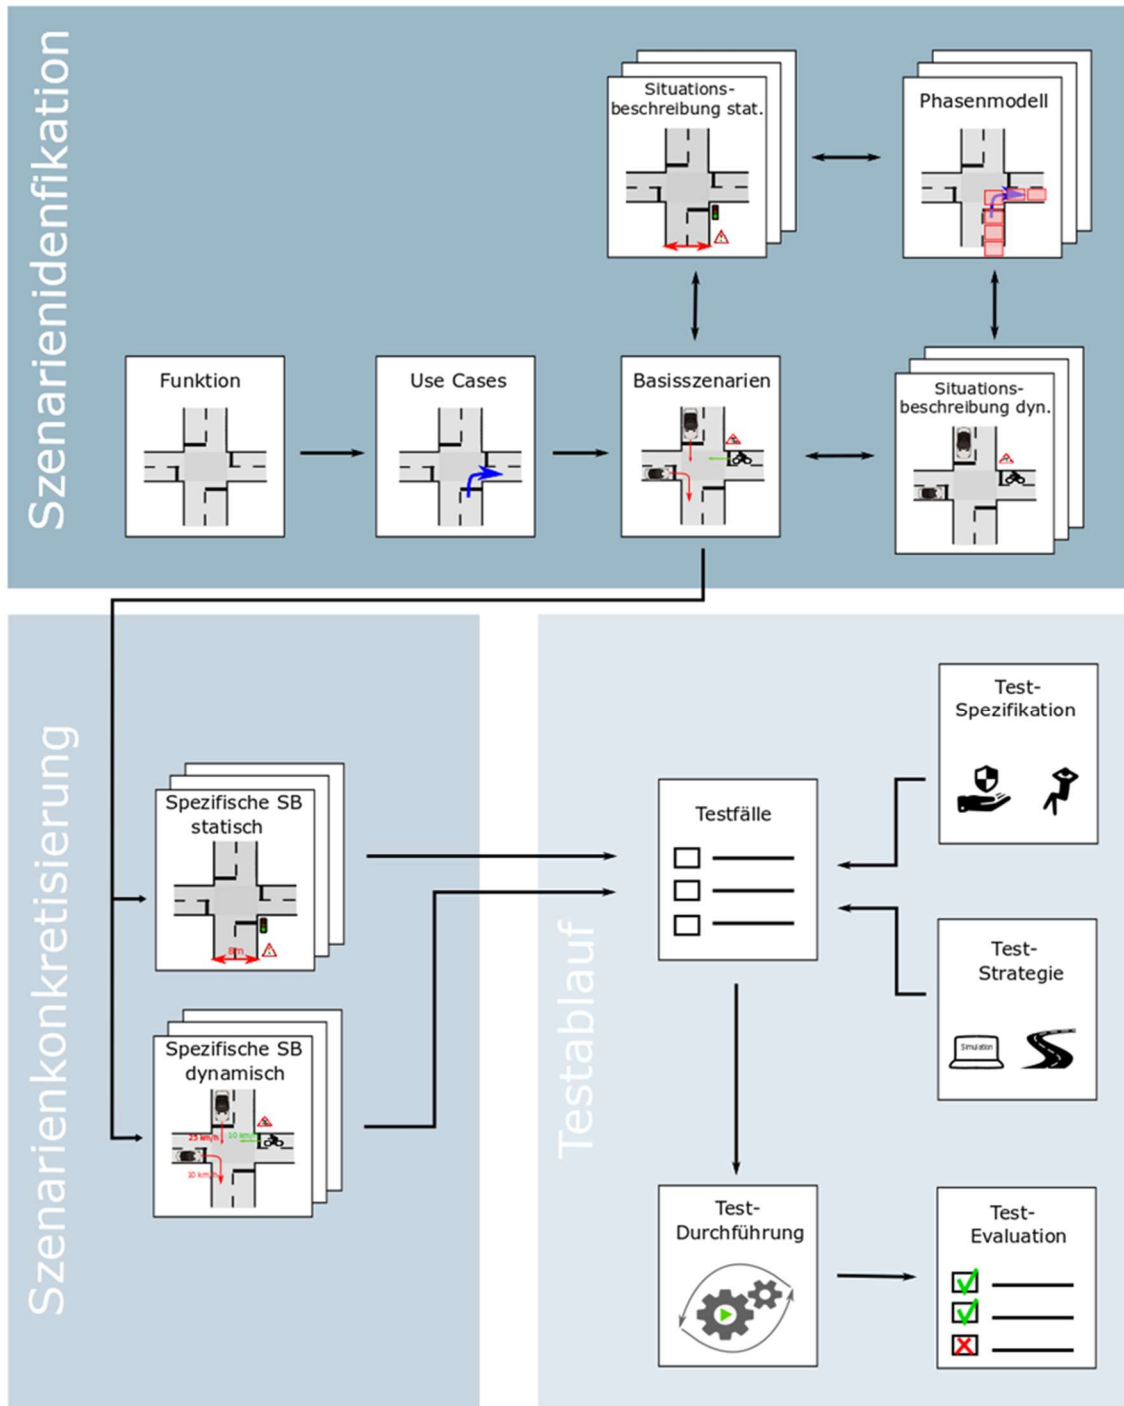


Abbildung 87: Übersicht initiale Testmethodik @CITY am Beispiel von urbanen Knotenpunkten



1.4. Literaturverzeichnis

[OECD, 2010]

IRTAD International Traffic Safety Data and Analysis Group at OECD (2010):
Pressemitteilung: A Record Decade for Road Safety, www.irtad.net

[BAST, 2000, 2010]

Bundesanstalt für Straßenwesen (2000, 2010): Verkehrs- und Falldaten –
Kurzzusammenfassung der Entwicklung in der Bundesrepublik Deutschland,
www.bast.de

[SCHMITT ET AL., 2007]

F. Schmitt and M. Maurer, "Simulation des Bremsverhaltens in
Gefahrensituationen mittels experimentell validiertem Fahrermodell", In Der
Mensch im 21. Jahrhundert, 2007



2. Anderweitige Fortschritte auf dem Gebiet des Vorhabens

Außerhalb des Forschungsvorhabens wurden ähnlich umfangreiche Ansätze im Bereich von Endkundenfahrzeugen nicht beobachtet. Insofern kann das Vorhaben als Schrittmacher auf dem Weg zu intelligenten und sicheren Fahrzeugen eingestuft werden.

3. Veröffentlichungen

C. Vogl, M. Sackmann, L. Kürzinger, and U. Hofmann, “Frenet Coordinate Based Driving Maneuver Prediction at Roundabouts Using LSTM Networks,” in *Computer Science in Cars Symposium*, Feldkirchen Germany, Dec. 2020, pp. 1–9. doi: [10.1145/3385958.3430475](https://doi.org/10.1145/3385958.3430475).

M. Sackmann, H. Bey, U. Hofmann, and J. Thielecke, “Prediction Error Reduction of Neural Networks for Car-Following Using Multi-Step Training,” in *2020 IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC)*, Sep. 2020, pp. 1–7. doi: [10.1109/ITSC45102.2020.9294646](https://doi.org/10.1109/ITSC45102.2020.9294646).

T. Leemann, M. Sackmann, J. Thielecke, and U. Hofmann, “Distribution Preserving Multiple Hypotheses Prediction for Uncertainty Modeling,” in *ESANN 2021 proceedings*, Online event (Bruges, Belgium), 2021, pp. 523–528. doi: [10.14428/esann/2021.ES2021-16](https://doi.org/10.14428/esann/2021.ES2021-16).

M. Sackmann, H. Bey, U. Hofmann, and J. Thielecke, “Learning a Diverse and Cooperative Policy for Predicting Roundabout Traffic Situations,” in *14. Workshop Fahrerassistenz und automatisiertes Fahren*, Berkheim, Germany, 2022.

M. Sackmann, H. Bey, U. Hofmann, and J. Thielecke, “Learning a Diverse and Cooperative Policy for Predicting Roundabout Traffic Situations,” in *14. Workshop Fahrerassistenz und automatisiertes Fahren*, Berkheim, Germany, 2022.

M. Sackmann, H. Bey, U. Hofmann, and J. Thielecke, “Modeling Driver Behavior using Adversarial Inverse Reinforcement Learning,” in *IEEE Intelligent Vehicles Symposium*, 2022.

M. Sackmann, H. Bey, U. Hofmann, and J. Thielecke, “Classification of Driver Intentions at Roundabouts,” VEHITS 2020.

M. Sackmann, T. Leemann, H. Bey, U. Hofmann, and J. Thielecke, “Multi-Step Training for Predicting Roundabout Traffic Situations,” in *IEEE International Intelligent Transportation Systems Conference*, Indianapolis, USA, 2021. doi: [10.1109/ITSC48978.2021.9564547](https://doi.org/10.1109/ITSC48978.2021.9564547).



F. Konstantinidis, M. Sackmann, O. De Candido, U. Hofmann, J. Thielecke, and W. Utschick, "Parameter Sharing Reinforcement Learning for Modeling Multi-Agent Driving Behavior in Roundabout Scenarios," in *IEEE International Intelligent Transportation Systems Conference*, Indianapolis, USA, 2021. doi: [10.1109/ITSC48978.2021.9565031](https://doi.org/10.1109/ITSC48978.2021.9565031).

Bey, H., Sackmann, M., Lange, A., & Thielecke, J. (2021, July). POMDP Planning at Roundabouts. In *2021 IEEE Intelligent Vehicles Symposium Workshops (IV Workshops)* (pp. 264-271). IEEE.

Berichtsblatt

1. ISBN oder ISSN	2. Berichtsart (Schlussbericht oder Veröffentlichung) Schlussbericht	
3. Titel @City – Automated Cars and Intelligent Traffic in the City		
4. Autor(en) [Name(n), Vorname(n)] Siedersberger, Karl-Heinz, Dr.-Ing. Hofmann, Ulrich, Dr.-Ing.	5. Abschlussdatum des Vorhabens 30.06.2022	
	6. Veröffentlichungsdatum 21.12.2022	
	7. Form der Publikation Schlussbericht	
8. Durchführende Institution(en) (Name, Adresse) AUDI AG 85045 Ingolstadt	9. Ber. Nr. Durchführende Institution	
	10. Förderkennzeichen *) 19A17015I	
	11. Seitenzahl 84	
12. Fördernde Institution (Name, Adresse) Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 11019 Berlin	13. Literaturangaben	
	14. Tabellen 1	
	15. Abbildungen 87	
16. Zusätzliche Angaben		
17. Vorgelegt bei (Titel, Ort, Datum)		
18. Kurzfassung <p>@CITY hatte das Ziel, ein neues, automatisiertes Fahrerlebnis für das sichere, stressfreie, effiziente und komfortable Fahren in der Stadt zu generieren. Automatisierte Fahrzeuge und intelligenter Verkehr sind die zentralen Elemente für den Stadtverkehr der Zukunft. Automatisierte Fahrzeuge, auch Fahrzeuge für Endkunden sind dabei ein wichtiger Baustein.</p> <p>In den 3 Teilprojekten „Umfelderfassung und Situationsverstehen“, „Digitale Karte und Lokalisierung“ und „Konzepte und Pilotanwendung“ wurden Grundlagen für das automatisierte Fahren in der Stadt gelegt.</p> <p>Im Rahmen des Teilprojektes „Umfelderfassung und Situationsverstehen“ hat die AUDI AG neuartige Verfahren und Methoden entwickelt, um die komplexen Verkehrssituationen im urbanen Umfeld erkennen und interpretieren zu können. Eine leistungsfähige und robuste Umfeldwahrnehmung ist die Basis für automatisierte Fahrfunktionen, welche ein sicheres, effizienteres und entspannteres Fahren in der Stadt anstreben.</p> <p>Im Teilprojekt „Digitale Karte und Lokalisierung“ wurde seitens Audi ein sensorbasierte Lokalisationsverfahren entwickelt, welches auf einer HD-Karte beruht und eine ähnliche Genauigkeit wie GNSS-basierte Lokalisierungsverfahren aufweist.</p> <p>Das Teilprojekt „Konzepte und Pilotanwendungen“ stand ganz im Zeichen der formalen Beschreibung von Szenarien, des Soll-Verhaltens und der Testmethodik und lieferte somit die Grundlage für die Arbeiten in @City und darüber hinaus.</p> <p>Alle von der AUDI AG angestrebten Untersuchungen wurden erfolgreich abgeschlossen und werden in Zukunft einen großen Beitrag dazu leisten, automatisiertes Fahren im urbanen Umfeld Wirklichkeit werden zu lassen.</p>		
19. Schlagwörter Automatisiertes Fahren, Urbane Fahrfunktion, Umfeldwahrnehmung, Digitale Karte, Lokalisierung		
20. Verlag	21. Preis	

Document Control Sheet

1. ISBN or ISSN	2. type of document (e.g. report, publication) Final report
3. title @City – Automated Cars and Intelligent Traffic in the City	
4. author(s) (family name, first name(s)) Siedersberger, Karl-Heinz, Dr.-Ing. Hofmann, Ulrich, Dr.-Ing.	5. end of project 30.06.2022
	6. publication date 21.12.2022
	7. form of publication Final report
8. performing organization(s) (name, address) AUDI AG 85045 Ingolstadt	9. originator's report no.
	10. reference no. 19A17015I
	11. no. of pages 84
12. sponsoring agency (name, address) Bundesministerium für Wirtschaft und Klimaschutz (BMWK) 11019 Berlin	13. no. of references
	14. no. of tables 1
	15. no. of figures 87
16. supplementary notes	
17. presented at (title, place, date)	
18. abstract The goal of @CITY was the development of new automatic driving features for a safe, efficient and comfortable ride in urban environment. Automatic vehicles and intelligent traffic are key-elements for urban traffic in future. Automatic driving functions in customer cars are important elements for this. The basics for automatic driving in urban environment were developed in 3 subprojects "Environment perception and Situation understanding", "Digital Map and Localization" and "Concepts and Pilot applications". AUDI AG was involved in all 3 subprojects. In subproject "Environment perception and Situation understanding" Audi developed new methods to detect und interpret complex urban traffic situations. In subproject "Digital Map and Localization" a sensor-based localization module for urban environment were developed with a similar accuracy like GNSS-based localization systems. Last but not least in subproject "Concepts and Pilot applications" basic stuff e.g. scenario description, behavior description of the ego-vehicle and testmethods were developed. These are the backbone of all activities in @CITY and @CITY-AF All Audi activities were successful and will be the source for new urban automatic driving functions in customer cars.	
19. keywords Automatic Driving, Urban Driving Features, Environment Perception, Digital Map, Localisation	
20. publisher	21. price