

Verbundbericht SAFARI

Gemeinsamer Sachbericht nach 6.2 ANBest-Gk

ZE: -

Förderkennzeichen: **16AVF1029**

Vorhabenbezeichnung: **Sicheres automatisiertes und vernetztes Fahren mit selbstaktualisierenden Karten**

Laufzeit des Vorhabens: **01.07.2017 – 31.12.2019**

Schutzklasse Öffentlich

Version 1.0

Stand 17.04.2020

Dokumenteninformation

Autoren

Luca Ricci – SenUVK

Stefanie Bauling – SenWEB

Oliver Strop – BLIC/ scope

Eric Dörheit, Sebastian Bunk- DCAITI

Birgit Kwella, Helge Rosè – FOKUS

Claas-Norman Ritter, Nicolai Steinke – DCMLR/FU Berlin

Ralph Hänsel, Michael Holicki – HELLA Aglaia

Jens Rohrbeck – IAV

Koordinator

Land Berlin vertreten durch

Senatsverwaltung für Umwelt, Verkehr und Klimaschutz Berlin

Dipl.-Ing. Michael Beer

Am Köllnischen Park 3

10179 Berlin

Tel.: 030 – 9025-1431

E-Mail: Michael.Beer@SenUVK.berlin.de

Förderung

Das Vorhaben SAFARI wird vom Bundesministerium für Verkehr und digitale Infrastruktur (BMVI) im Rahmen der Förderrichtlinie „Automatisiertes und Vernetztes Fahren auf digitalen Testfeldern in Deutschland“ gefördert.

Inhaltsverzeichnis

Verbundbericht SAFARI	i
1 Einleitung	8
1.1 Ausgangssituation	8
1.1.1 Herausforderung Automatisiertes und Vernetztes Fahren	8
1.1.2 Sensorik	8
1.1.3 Kommunikationstechnologie	13
1.1.4 Hochgenaue Karten und Kartenaktualisierung	15
1.2 Szenarien	18
1.3 Zielsetzung	19
2 Wissenschaftlich-technische Ergebnisse und wesentliche Ereignisse	20
2.1 AP 1 Projektmanagement und Ergebnisverbreitung	20
2.2 AP 2 Gesamtkonzeption	21
2.2.1 AP 2.1 Analyse Ist-Zustand und Randbedingungen	21
2.2.2 AP 2.2 Anforderungsanalyse und Systemkonzeption	21
2.2.3 AP 2.3 Technische Koordinierung	28
2.3 AP 3 Umfeldwahrnehmung	28
2.3.1 AP 3.1 Freiraumerkennung	28
2.3.2 AP 3.2 Selbstlokalisierung	37
2.3.3 AP 3.3 Anpassung der Sensorik an Versuchsfahrzeuge	42
2.4 AP 4 Kommunikationsmanagement und Backend	48
2.4.1 AP 4.1 Kommunikationsmanagement und Vorverarbeitung	48
2.4.2 AP 4.2 Austauschformate	51
2.4.3 AP 4.3 Sicherheitsarchitektur	52
2.4.4 AP 4.4 Hardware/ Software-Umsetzung	52
2.5 AP 5 Selbstaktualisierende Karte	53
2.5.1 AP 5.1 Datenbankadministration	54
2.5.2 AP 5.2 Klassifikation	55
2.5.3 AP 5.3 Referenzerzeugung	55
2.5.4 AP 5.4 Veränderungsdetektion	55
2.5.5 AP 5.5 Verkehrsmanagement	58
2.6 AP 6 Systemintegration	58

2.6.1 AP 6.1 SW-Komponenten zur Selbst- und Objektlokalisierung	58
2.6.2 AP 6.2 SW-Komponenten zur Kommunikation	60
2.6.3 AP 6.3 SW-Komponenten zur Kartenverwendung	60
2.6.4 AP 6.4 Tests, Gesamtintegration und Datenaufzeichnung	61
2.7 AP 7 Demonstration und Evaluation	61
2.7.1 AP 7.1 Vorbereitung der Demonstration	61
2.7.2 AP 7.2 Durchführung der Demonstration	62
2.7.3 AP 7.3 Eigenevaluation	69
3 Vergleich Planung und Umsetzung des Vorhabens	71
3.1 Arbeitsplanung	71
3.1.1 Erprobung der Anwendungen auf Basis LSA-seitiger Roadside Units	71
3.1.2 Erprobung von Small Cells	72
3.1.3 Datenerfassung im Fahrzeug	72
3.1.4 Digitalisierung und Integration der Verwaltungsprozesse	72
3.1.5 Weiterentwicklung der Smartphone-App	72
3.2 Zeitplanung	73
4 Ziele des Vorhabens	74
4.1 Relevante F&E-Ergebnisse Dritter	74
4.2 Änderungen der Zielsetzung	77
Abkürzungsverzeichnis	78

Abbildungsverzeichnis

Abbildung 2-1: Use Case Übersicht	22
Abbildung 2-2: Ebenen der Systemarchitektur	23
Abbildung 2-3: Aufnahme aus dem Versuchsgebiet. Links: Originalbild, Rechts: Ergebnis aus der semantischen Segmentierung.....	29
Abbildung 2-4: Visualisierung der Suchlinien mit der aus der Kamera-Kalibrierung errechneten relativen Entfernung zum Fahrzeug.	30
Abbildung 2-5: Parklücke zwischen Fahrzeugen, erkannt als Zone von Straße-Gehweg-Übergang (gelbe Linie) zwischen zwei Zonen mit Straße-Fahrzeug-Übergang.....	31
Abbildung 2-6: Die Freiraumerkennung detektiert ein Fahrzeug als Hindernis mitten auf der Fahrspur.	31
Abbildung 2-7: Erkennung der Baustellenbaken und -zäune als extra antrainierte Klassen (links). Ergebnis aus der koordinierten Datenakquise, wo Freiraum und Baustellenbaken zu erkennen sind.	32
Abbildung 2-8: Der aus den 32-Strahl-LiDAR Daten mittels optimierten Algorithmus erkannte, absolute Freiraum (grüne Polygonlinie).....	33
Abbildung 2-9: Erkennung und Klassifikation von dynamischen Objekten durch die Anwendung eines Deep Learning Netzwerks Car (rot), Bicycle (blau), Pedestrian (grün).	34
Abbildung 2-10: Die Projektion der 2D-Bounding Boxen in die 3D-LiDAR-Daten realisiert einen sehr einfachen 3D-Box-Detektor.	34
Abbildung 2-11: Kamerabasierte Lokalisierung, generelles Verfahren: Aus den Daten der Kamera werden Objekte wie Freiräume, semantische Objekte (z.B. Verkehrsschilder) oder Spurmarkierungen extrahiert. Diese werden dann unter Verwendung der Fahrzeugodometrie sowie eines GPS-Sensors mit einer externen Karte abgeglichen und daraus die Position und Lage des Fahrzeugs bestimmt.	37
Abbildung 2-12: Senatskarte des Versuchsgebietes. Links: Gesamtansicht, Rechts: Detailansicht (die unbekanntenen Höhen der Schildobjekte wurden dabei durch nominelle Höhen ersetzt).....	38
Abbildung 2-13: Aus dem Einzelbild extrahierte Objekte: Spurmarkierungen (orange) und Detektionen aus dem Deep Learning (blau) wie Bodenmarkierungen, Schilder und Ampeln	39
Abbildung 2-14: Links: inkorrekte Lokalisierung, Rechts: korrekte Lokalisierung. Anhand der rückprojizierten Kartenelemente (Fahrbahnmarkierungen, Ampeln und Schilder) kann ein menschlicher Auswerter beurteilen, ob diese korrekt über den im Bild sichtbaren Elementen liegen.	39
<i>Abbildung 2-15: Fahrt 1 vom 28.2.2019 blau: HELLA Aglaia Lokalisierung, grün: GPS/Fahrzeugodometrie Fusion, links oben: Kreuzung Scharnweberstraße/Ollenhauerstraße,</i>	

<i>rechts oben: Kreuzung Scharnweberstraße/Eichborndamm, links unten: Kreuzung Eichborndamm/Waldstraße, rechts unten: Kreuzung Waldstraße/Ollenhauerstraße</i>	40
Abbildung 2-16: Beispiel für Lokalisierung der DCAITI-VT: blau – Landmarken in der Karte, weiß detektierte Landmarken, rot - LiDARpunktvolken	41
Abbildung 2-17: Fahrzeug HELLA Aglaia	43
Abbildung 2-18: Systemkomponenten HELLA Aglaia.....	44
Abbildung 2-19: Gesamtarchitektur Fahrzeug, HELLA Aglaia	44
Abbildung 2-20: Zweite Version des 3D-Vision Rigs.	45
Abbildung 2-21: Resultierende Einzeldaten und Gesamtsicht mit Rig Version 2 (Front/Seiten-Kameras+LiDAR, Beispiel einer Datenakquise im Testgebiet und Freiraum- und Objekterkennung)	46
Abbildung 2-22: Detektierte, getrackte und erkannte Objekte des VT der DCMLR/FU	47
Abbildung 2-23: <i>detektierte und getrackte Objekte mit dem Fingerprint Lokalisierungsverfahren</i> ..	47
Abbildung 2-24: Darstellung der untersuchten alternativen Kommunikationswege.....	50
Abbildung 2-25: Darstellung des SAFARI-Backend.....	54
Abbildung 2-26: Erkennung und Klassifikation von Verkehrszeichen (gelbe Boxen) als statische Objekte durch die Anwendung eines weiteren Deep Learning Netzwerks durch 3D Vision (DCAITI).	57
Abbildung 2-27: Prognosewahrscheinlichkeiten für erkannte Verkehrszeichen	57
Abbildung 2-28: <i>Abbildung der 3 VT von (v.l.n.r.) HELLA Aglaia, DCMLR/FU, DCAITI</i>	59
Abbildung 2-29: <i>Anwendungsszenario Landmarken (Darstellung der IAV)</i>	64
Abbildung 2-30: Anwendungsszenario Parken (links: HELLA Aglaia, rechts: DCMLR/FU).....	65
Abbildung 2-31: Anwendungsfall Baustelle (Demonstration HELLA Aglaia)	65
Abbildung 2-32: Anwendungsfall Lichtsignalanlage (Demonstration HELLA Aglaia)	66
Abbildung 2-33: <i>Demonstration DCAITI</i>	67
Abbildung 2-34 Objekt- und Freiraumerkennung der HELLA Aglaia Kamera	68

Tabellenverzeichnis

<i>Tabelle 2-1: Objekterkennung in SAFARI und Verantwortliche</i>	25
<i>Tabelle 2-2: Änderungsdetektion in SAFARI und Verantwortliche</i>	26

Kurzfassung

In dem Forschungsprojekt SAFARI erprobte das Land Berlin unter der Federführung der Senatsverwaltung für Umwelt, Verkehr und Klimaschutz (SenUVK), zusammen mit seinen Partnern den Austausch und die Aktualisierung digitaler Karten als einer der Grundvoraussetzungen für das automatisierte und vernetzte Fahren. Das Projekt wurde im Rahmen des Förderprogramms des BMVI, der „Strategie automatisiertes und vernetztes Fahren – Leitanbieter bleiben, Leitmarkt werden, Regelbetrieb einleiten“ (Strategie AVF), finanziell gefördert.

Der Aufbau des Testfeldes wurde durch die Senatsverwaltung für Umwelt, Verkehr und Klimaschutz vorbereitet, die dabei konsequent auf den Ausbau und die Modernisierung vorhandener Infrastruktur setzte. Mit der Integration in ihre kommunalen Prozesse stellt das Land Berlin zudem sicher, dass die im Testfeld vorhandene Infrastruktur auch über die Projektlaufzeit der aktuellen Förderung durch das BMVI hinaus weiter betrieben wird. Damit steht dieses digitale Testfeld auch Dritten über das Ende des eigenen Projektes hinaus offen und das Land Berlin lädt nach wie vor ausdrücklich dazu ein, hier die Zukunft des automatisierten und vernetzten Fahrens im Stadtverkehr intensiv zu erforschen, zu entwickeln und zu erproben.

Im Rahmen von SAFARI wurde mit einer Flotte von Fahrzeugen die Grenzen der Leistungsfähigkeit der Sensoriken automatisierter und autonomer Fahrzeuge getestet. Dabei traten vollautomatisierte Fahrzeuge mit der „Lizenz“ zum autonomen Fahren mit Sicherheitsfahrer, mit heutiger serienreifer Kamertechnik ausgerüstete Serienfahrzeuge und sogar Smartphones gegeneinander an.

Neben der SenUVK Berlin beteiligten sich an dem/m Vorhaben SAFARI weitere Akteure der öffentlichen Hand (Senatsverwaltung für Wirtschaft, Energie und Betriebe, Verkehrslenkung Berlin, Bezirksamt Reinickendorf), Universitäten und Forschungseinrichtungen (Dahlem Center for Machine Learning and Robotics der Freien Universität Berlin, Fraunhofer Institut für Offene Kommunikationssysteme (FOKUS), Technische Universität Berlin mit dem Daimler Center for Automotive IT Innovations (DCAITI)) und Wirtschaftsunternehmen (IAV GmbH, HELLA Aglaia Mobile Vision GmbH, Deutsche Telekom AG).

1 Einleitung

1.1 Ausgangssituation

1.1.1 Herausforderung Automatisiertes und Vernetztes Fahren

Die hochgenauen Karten und Ihre Aktualisierung sind für alle Stakeholder im Bereich des Automatisierten und Vernetzten Fahrens (AVF) wie Fahrzeughersteller, Zulieferindustrie oder Diensteanbieter sowie öffentliche Straßenbauverwaltungen von hoher Wichtigkeit und Dringlichkeit. Sie werden entsprechend in einer Vielzahl öffentlich geförderter, aber auch sorgsam gehüteter Industrie-, Forschungs- und Entwicklungsprojekte in allen Industrienationen vorangetrieben.

Für das Land Berlin liegen hochgenaue Karten vor, die im Hinblick auf die verschiedenen Aufgaben des Verkehrsmanagements und Erhaltungsmanagements erhoben und klassifiziert wurden. Die HD-Karten stellen derzeit 80 Objekttypen und bis zu 28 Attribute pro Objekt zur Verfügung. Die statischen Daten entsprechen dem Format gemäß OKSTRA (Objektkatalog Straße¹).

Ohne ständige Aktualisierung unterliegen die statischen Daten wie Geometrien der Fahrbahnen oder dauerhaft angeordnete Verkehrszeichen einer stetigen Alterung. Ereignisse wie Baustellen oder andere verkehrsrechtliche Anordnungen werden als sog. semi-dynamische Daten in eigenen Layern ergänzt. Sie unterliegen unter Umständen täglichen Änderungen.

Urbane Szenarien und Innenstädte sind bisher ein schwer beherrschbares Terrain für die automatisierten und vernetzten Fahrzeuge. Die große Anzahl an zu beachtenden Objekten, das Verhalten menschlicher Verkehrsteilnehmer und nicht zuletzt ständige Änderungen im Straßenraum sind riesige Herausforderungen.

Entsprechend wird als Ausgangspunkt der Beschreibung die Sensorik der AVF gewählt und damit die Frage, mit welchen Erfassungssystemen derzeit gearbeitet wird. Daran anschließend wird der Stand der Umfelderkennung beschrieben („Was sehen die Fahrzeuge?“).

Die Vernetzung mit kommunaler und privatwirtschaftlicher Infrastruktur (V2X) steht im Mittelpunkt des Abschnitts Kommunikation.

Schwerpunkt ist die Darstellung des Standes hochgenauer Karten und Kartenaktualisierungen.

1.1.2 Sensorik

Moderne Fahrzeuge verfügen über vielfältige Fahrerassistenzfunktionen, welche den Fahrer bei der Fahrt unterstützen oder auch in kritischen Situationen, z.B. durch Notbremsungen, eingreifen.

¹ Es wurde die im Jahr 2014 gültige Version herangezogen.

- **Monokulare Frontkamera**

Ein möglicher Sensor stellt hierbei die **Monokulare Frontkamera** dar. Auf Basis dieser Kamera werden grundlegende Erkennungsfunktionen, wie die Fahrspur-, Verkehrszeichen- oder Personen- und Fahrzeugerkennung umgesetzt. Die aktuellen Entwicklungen zeigen hier auch komplexe Sensorfunktionen, wie die Freiraumerkennung oder die Erkennung komplexer Verkehrssituationen.

In den kommenden Jahren gewinnen vorrangig Anwendungsfälle im Bereich des autonomen und urbanen Fahrens an Bedeutung. Dadurch werden auch die Anforderungen an das Kamerasystem hinsichtlich des Erfassungsbereiches (Öffnungswinkel) und der Detektionsreichweite erhöht. Nach dem aktuellen Stand der Technik werden seriennahe Kamerasysteme zukünftig über einen horizontalen Öffnungswinkel von 100° mit einer Auflösung von 2 Megapixeln verfügen. Der Erfassungshorizont für die Erkennung von anderen Fahrzeugen (Pkw) liegt damit bei ca. 100 m.

- **LiDAR-Sensor**

Ein weiterer verbreitet eingesetzter Sensortyp sind **LiDAR-Sensoren**. Sensoren von der Firma Velodyne, einem der bekanntesten Hersteller, bieten meist eine 360 ° (Grad) Rundumsicht. Diese Sensoren gibt es in verschiedenen Ausführungen von 64, 32 oder 16 vertikal übereinander angeordneten Laserstrahlen. Die Sensoren werden fast immer auf dem Dach der Fahrzeuge montiert. Die verschiedenen Laserstrahlen erfassen die Umgebung in verschiedenen Winkeln. In Kombination mit den 360 ° Rundumscans eignet sich diese Art Sensoren insbesondere für die Nahfelderfassung sowie für Objekte in Entfernungen von bis zu 100 Metern. Demgegenüber stehen Sensoren, wie sie z.B. von der Firma Ibeo (Lux) oder Valeo (Scala) hergestellt werden. Die Anzahl der Laserscanzeilen ist hier meist auf 4-8 begrenzt. Der Vertikale Öffnungswinkel ist mit 4-8 Grad, ebenso wie der horizontale Öffnungswinkel (ca. 90-120 Grad) recht klein. Die Stärke der Sensoren, die meist in ca. 20-50 cm Höhe verbaut werden, liegt in ihrer hohen Reichweite von bis zu 200 Metern, was sie sehr gut für die Erfassung von Hindernissen bzw. anderen Fahrzeugen auf der Fahrbahn prädestiniert. Oft (jedoch nicht immer) werden diese Sensoren im Verbund von 4-8 Scannern, welche in verschiedene Richtungen orientiert werden, verwendet. Jedoch sind auch Lösungen möglich, bei denen ein einzelner Sensor lediglich die Fahrzeuge oder Objekte in Fahrtrichtung erfasst.

Ein Nachteil, den alle bisher genannten LiDAR-Sensoren gemein haben, sind die hohen Herstellungskosten. Diese sind zum Teil der komplexen Mechanik mit rotierenden Sensoren oder rotierenden Spiegeln geschuldet. Aus diesem Grund wird derzeit viel Forschungsaufwand in

die Entwicklung von Solid-State-LiDAR Sensoren investiert, die ohne bewegliche mechanische Teile auskommen. Über verschiedene Halbleiterelemente, Flüssigkristallstrukturen sowie Polarisationsfilter ist es hier möglich, Laserstrahlen ohne mechanische Komponenten so zu steuern, dass weiterhin Objekte in unterschiedlichen horizontalen und vertikalen Winkeln erfasst werden können. Leider befinden sich diese Sensoren noch im Prototypenstadium. Damit ist die Verfügbarkeit solcher Solid-State-Sensoren auf dem Markt noch nicht gegeben.

Bestehende Sensorik setzt zumeist auf eine Vision-basierte 2D-Lösung (Kamera) mit detaillierten Farbinformationen und hoher Auflösung oder auf einen 3D-Sensor, wie beispielsweise LiDAR. In der Erprobung sind derzeit Sensoriken, die die Stärken beider Ansätze kombinieren, indem die Daten bereits auf niedrigem Level vereint werden (sogenannte Early Fusion). Ziel ist somit die Fusion zur Erstellung von Vision-basierten 3D-Sensordaten. Mögliche Ansätze bestehen in der Verwendung einer Stereokamera (bestehend aus 2 Monokameras) oder auch die Kombination aus einer Monokamera zusammen mit einem LiDAR. Während die Stereokamera bereits vor einiger Zeit Serienreife erlangt hat, ist die LiDAR-Kamera-Kombination noch in der Entwicklungsphase, nicht zuletzt aufgrund der hohen Kosten für den LiDAR.

Durch den Einsatz des LiDAR kann eine genaue Entfernungsbestimmung bis ca. 100 m erfolgen, wohingegen die Genauigkeit von Stereokameras mit zunehmender Entfernung aufgrund der begrenzten Kameraauflösung sinkt. Dem gegenüber steht die hohe Auflösung der 3D Punkte, welche durch die Stereokamera erzeugt werden. LiDAR-basierte Ansätze sind durch die Anzahl an Laserstrahlen limitiert.

- **360° 3D-Umfeldwahrnehmung**

Der Erfassungshorizont für Kamerasysteme hängt sowohl von den eingesetzten Sensoren als auch von den Objektiven ab. Für eine 360° Umfeldwahrnehmung werden üblicherweise vier bis sechs Weitwinkelkameras eingesetzt. Um auch Objekte in größerer Entfernung zu erfassen, werden zudem Teleobjektive eingesetzt. Diese sind vorrangig in Fahrtrichtung ausgerichtet, da sie insbesondere bei hoher Eigengeschwindigkeit erforderlich werden. Für eine vollständige 360° 3D-Umfeldwahrnehmung mittels Stereokameras sind demzufolge acht bis zwölf Sensoren erforderlich. Ein einzelner 360° LiDAR sowie vier bis sechs Kameras ermöglichen ebenfalls eine vollständige **360° 3D Vision** zur Objekterkennung.

- **Android-Smartphones**

Die in Android-Smartphones verbaute Sensorik aus hochauflösenden Kameras, GPS und IMU wird bereits in einigen Bereichen eingesetzt:

- Augmented Reality Anwendungen
- Fußgängerlokalisierung und Navigation

Je nach Qualität der in Smartphones verbauten Kameras variieren die Leistungsdaten dabei erheblich. Dennoch haben erste Untersuchungen gezeigt, dass moderne Deep-Learning-Verfahren prinzipiell dazu in der Lage sind, einen Teil der Qualitätsvariation der Daten zu kompensieren und somit zufriedenstellende Perzeptionsergebnisse zu liefern. In aktuellen Geräten kamen bereits zu Untersuchungszwecken spezielle Verarbeitungseinheiten zum Einsatz, die den Einsatz neuronaler Netze und anderer Algorithmen des maschinellen Lernens (ML, engl. Machine-Learning) im Mobilbetrieb ermöglichen. Damit gehört diese Lösung zu den „low-cost low-perception“ Lösungen, da durch die Verwendung eines Smartphones auf eine Standard-Technologie für Sensorik und Rechenleistung im Feld zurückgegriffen wird, 2Umfelderfassung

Die Umfelderfassung über Mono-Kamerasysteme ist in vielen Kontexten bereits etablierte Praxis. In unserem Anwendungsfall sind insbesondere Fahrerassistenzsysteme verschiedener Hersteller zu nennen, die basierend auf der Frontkamera Detektionsaufgaben übernehmen, wie die Erkennung von Fahrspuren, Fußgängern, Verkehrszeichen und Fahrzeugen.

Im SAFARI-Projekt werden über den industriellen Stand der Technik hinaus Algorithmen aus dem Bereich Deep Learning zum Einsatz kommen, die sich teilweise auf wissenschaftliche Arbeiten stützen. Da in diesem Bereich aktiv geforscht wird, sollen hier einige der grundlegenden wissenschaftlichen Arbeiten genannt werden.

- Multi-Objekt-Detektion:

Shaoqing Ren, Kaiming He, Ross Girshick, and Jian Sun. Faster r-cnn: Towards real-time object detection with region proposal networks. In *Advances in neural information processing systems*, pages 91–99, 2015.

Wei Liu, Dragomir Anguelov, Dumitru Erhan, Christian Szegedy, Scott Reed, Cheng-Yang Fu, and Alexander C Berg. Ssd: Single shot multibox detector. In *European Conference on Computer Vision*, pages 21–37. Springer, 2016.

- Semantic Segmentation

Vijay Badrinarayanan, Alex Kendall, Roberto Cipolla: SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation, arXiv preprint arXiv:1511.00561, 2015

² Dies stellt keine Aussage über die Kosten der anderen Technologien dar.

Hengshuang Zhao, Xiaojuan Qi, Xiaoyong Shen, Jianping Shi, Jiaya Jia: ICNet for Re-al-Time Semantic Segmentation on High-Resolution Images, arXiv preprint arXiv:1704.08545, 2017

Der derzeitige Stand der Technik zur Selbstlokalisierung von Kamerasystemen relativ zu externen Referenzen zerfällt in zwei Gruppen.

Merkmalsbasierte Ansätze verwenden 3D-Karten mit Low-Level-Merkmalen, wie Featurepunkten³ oder Liniensegmenten⁴. Diese Karten werden dabei durch Structure from Motion bzw. SLAM Verfahren erzeugt (linienbasiert⁵ oder feature-basiert⁶). Zum initialen Matching von Karte zu lokaler Detektion kommen dann Bag-of-Word Verfahren⁷, aber auch modernere Ansätze, wie etwa Deep Learning Verfahren⁸, zum Einsatz. Diese Verfahren sind im Allgemeinen sehr genau und funktionieren für viele verschiedene Szenarien. Nachteile sind die relativ hohe Menge an Daten, die für die Karten erforderlich sind, sowie die mangelnde Robustheit gegenüber veränderten Umweltbedingungen zwischen Kartenerzeugung und Lokalisierung (Wetterunterschiede, Tag/Nacht, jahreszeitliche Unterschiede).

Neben den merkmalsbasierten Ansätzen gibt es auch Verfahren, die Landmarken, also High-Level Objekte mit semantischer Bedeutung verwenden. Solche Objekte können z.B. 3D Masten⁹, Verkehrsschilder¹⁰ oder Straßenmarkierungen¹¹ sein. Diese Objekte werden mit Methoden des ML aus den Sensorbildern extrahiert und mit einer bestehenden Karte, die diese Objekte enthält, abgeglichen. Aufgrund des hohen Abstraktionsgrades der verwendeten Landmarken sind diese

³ Ferber, M., et al. "Combining SURF and SIFT for Challenging Indoor Localization using a Feature Cloud" Proceedings of the Seventh International Conference on Indoor Positioning and Indoor Navigation. IEEE, (2016).

⁴ Vidal-Calleja, T, et al. "Large scale multiple robot visual mapping with heterogeneous landmarks in semi-structured terrain" Robotics and Autonomous Systems. 59. 654-674. 10.1016/j.robot.2011.05.008. (2011)

⁵ Lemaire, Thomas and Simon Lacroix. "Monocular-vision based SLAM using Line Segments" Proceedings IEEE International Conference on Robotics and Automation (2007): 2791-2796. (2007)

⁶ Mur-Artal, Raul & Montiel, J & Tardos, Juan. "ORB-SLAM: a versatile and accurate monocular SLAM system". IEEE Transactions on Robotics. 31. 1147 - 1163. 10.1109/TRO.2015.2463671. (2015)

⁷ Nuri Lee et al. "Development of indoor localization system using a mobile data acquisition platform and BoW image matching" KSCE Journal of Civil Engineering, January 2017, Volume 21, Issue 1, pp 418–430 (2017)

⁸ Sünderhauf, N. et al. "Place Recognition with ConvNet Landmarks: Viewpoint-Robust, Condition-Robust, Training-Free" Robotics: Science and Systems (2015).

⁹ Brenner, Claus. "Vehicle Localization Using Landmarks Obtained by a LIDAR Mobile Mapping System". International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives. 38. (2010)

¹⁰ Qu, X. et al.. "Vehicle localization using mono-camera and geo-referenced traffic signs" 2015 IEEE Intelligent Vehicles Symposium (IV): 605-610.(2015)

¹¹ Ranganathan, A. et al.. "Light-weight localization for vehicles using road markings". Proceedings of the ... IEEE/RSJ International Conference on Intelligent Robots and Systems. IEEE/RSJ International Conference on Intelligent Robots and Systems. 921-927. 10.1109/IROS.2013.6696460.(2013)

Verfahren vergleichsweise robust gegenüber veränderten Umwelteinflüssen und benötigen geringe Datenmengen.

Auch aus **LiDAR-Punktwolken** werden bei der Sensordatenverarbeitung Merkmale bzw. Objekte extrahiert, die über die Zeit verfolgt werden müssen, bzw. die im Fall der Selbstlokalisierung mit einer gegebenen Karte verglichen werden. Meist kommen für die zeitliche Integration der Sensordaten probabilistische Verfahren, wie Kalmanfilter, Multihypothesenmodelle oder Monte-Carlo-Partikelfilter zum Einsatz.

3D Vision als kombinierter Sensor ist dazu geeignet, die Grundlage für die Umsetzung der Lokalisierung und Umfeldwahrnehmung in AVF zu bilden. Aus den verschiedenen Sensorkombinationen, die hier verwendet werden, wird eine 3D-Umfeldabbildung abgeleitet. Basierend auf dieser Fusion der Sensordaten können Objekte, wie beispielsweise Fahrzeuge, Fußgänger, Radfahrer, erkannt und im dreidimensionalen Umfeldmodell lokalisiert werden. Die Kombination von 3D und Kameradaten ermöglicht dabei nicht nur die präzise Objektlokalisierung, sondern erhöht durch die bessere Datenlage gleichzeitig die Genauigkeit der Objekterkennung. Neben klassischen Verfahren der Objekterkennung, wie z. B. auf Basis von Discriminatively Trained Part-Based Models (<http://ieeexplore.ieee.org/document/5255236/>), können Deep-Learning-Verfahren eingesetzt werden. Letztere haben erstere in den vergangenen Jahren aufgrund ihrer überlegenen Genauigkeit nahezu verdrängt.

Im Bereich der Low-Cost Perzeption werden bereits erste Anwendungen mit Android-**Smartphones** als preisgünstige Hardware, die allen Verkehrsteilnehmern zur Verfügung steht, durchgeführt. Vorrangig sind hierbei Anwendungen im Bereich Augmented Reality und der Fußgängerlokalisierung und Navigation zu nennen. Im Vergleich zur High Cost Perzeption bestehen Unterschiede hauptsächlich in Hardwarelimitierungen im Bereich der Sensorik und der Rechenleistung.

Stand der Technik ist es, im hochgenau vermessenen öffentlichen Raum oder in Gebäuden, geometrische Objekte zu erkennen und anhand deren Verzerrung aus Sicht der Kameraperspektive die Lage des Smartphones zu bestimmen.

Die Umfelderkennung basiert dabei auf klassischen Verfahren und ML, die in Frameworks und Libraries, wie beispielsweise OpenCV, Tensorflow und Caffe2, bereits für den mobilen Bereich verfügbar sind. Dabei können einige der Erfassungsalgorithmen bereits auf neuesten Geräten mit speziellen Recheneinheiten ausgeführt werden.

1.1.3 Kommunikationstechnologie

Im Projekt SAFARI ist geplant, mit mehreren Versuchsträgern (Fahrzeuge und Mobiltelefone vgl. Kapitel 1.1.2) Objekt- und Verkehrsdaten zu erfassen. Die erfassten Daten müssen analysiert und

ggf. kommuniziert werden. Dabei kann die Kommunikation an unterschiedliche Instanzen gerichtet sein, wie z.B. andere Verkehrsteilnehmer, Infrastruktureinheiten – sogenannte Road Side Units (RSU) – und/oder das AVF-Backend. Aufgrund dieser Vielfältigkeit muss ein hybrides Kommunikationsgesamt-konzept entwickelt, umgesetzt und getestet werden. Es muss, den Anforderungen entsprechend, in der Lage sein, dynamisch die optimalen Kommunikationstechnologien zu nutzen. Das Konzept muss eine Datenvorverarbeitungs-, eine Datentransport- sowie eine geschlossene Sicherheitsarchitektur (Security-Strategie) enthalten.

Datenverarbeitung

Die Datenverarbeitung in SAFARI kann auf den mobilen Knoten (Fahrzeugen und Mobiltelefonen), den ggf. im Straßenland verbauten V2X-Kommunikationseinheiten (Roadside Units) und ggf. Edge-Processing Units (Multi-Access Edge Computing, MEC) und zentralenseitigen Infrastrukturdiensten (Backend bzw. Cloud Processing bei privaten und öffentlichen Diensteanbietern) erfolgen. Zu diesem Zwecke werden die Anforderungen der Anwendungen und Leistungsmerkmale der Kommunikationspfade analysiert und entsprechende Vor- und Weiterverarbeitungstechniken spezifiziert und implementiert.

Datentransport

Für jeden Use Case muss zunächst geklärt werden, welche Daten von den Versuchsträgern empfangen und ausgewertet werden müssen. Empfangen werden Daten über unterschiedliche Sensoren. Aktuell wird davon ausgegangen, dass im Versuchsträger verbaute Kameras Bildinformationen zu den Use Cases liefern. Zusätzlich sollen Kreuzungsinformationen via ITS G5 und zukünftig mittels des in Spezifikation befindlichen 5G-Standards detektiert werden können. Gegebenenfalls wird weitere Fahrzeugsensorik ausgewertet, um bspw. Parklücken zu erkennen. Darüber hinaus werden Aktualisierungen zwischen Fahrzeug und Backend mittels aktueller Mobilfunkstandards (3G und 4G) spezifiziert und realisiert.

Bei der Spezifikation sind Anforderungen zu berücksichtigen:

- Rechenleistungen zur Aufzeichnung und Datenanalyse in den Versuchsträgern, Android-Geräten, RSUs und dem Backend/der Cloud
- Maximal zulässige Latenz bei der Datenübertragung von der Quelle zum Ziel
- Minimal benötigter Datendurchsatz
- Auswahl geeigneter Übertragungstechnologien
- Updateverhalten/-bedarfe des Kartenmaterials

Security

Neben den zu entwickelnden Daten(vor)verarbeitungs- und Transportstrategien ist eine geschlossene Security-Strategie zu identifizieren und umzusetzen. Dabei wird auf State-of-the-Art Security Protokolle und Verfahren gesetzt.

Dabei werden folgende Forderungen gestellt:

- Die Kommunikationssicherheit betrachtet die Aspekte der Vertraulichkeit, Integrität, Verfügbarkeit und Authentizität von Informationen, die zwischen den Teilsystemen des SAFARI Projekts übertragen werden.
- Die Absicherung der Kommunikationsendpunkte erfolgt gemäß gängiger IT-Security Prinzipien und wird nicht weitergehend thematisiert.
- Auch bei Vorhandensein von Punkt-zu-Punkt Security-Maßnahmen wird unabhängig von diesen eine Ende-zu-Ende Absicherung der Kommunikationsinhalte gefordert.

Die konkrete Umsetzung dieser Ziele durch technische und organisatorische Maßnahmen ist Bestandteil der Projektarbeit. Konkrete bestehende Protokolle, deren Einsatz sehr wahrscheinlich ist, sind:

- ETSI TS 103 097 für den Bereich der ITS-G5-basierten Ad-Hoc Kommunikation
- TLS für den Bereich der IP-basierten verbindungsorientierten Kommunikation
- DTLS für den Bereich der IP-basierten verbindungslosen Kommunikation

1.1.4 Hochgenaue Karten und Kartenaktualisierung

Die Generierung von selbstaktualisierenden Karten wird in der Industrie, wie insbesondere von den wichtigen Kartenproduzenten, eigenständig oder in Kooperationsprojekten untersucht. Neben der räumlichen Auflösung interessieren sich die Hersteller in gleicher Maße für die zeitliche Aktualität. Im Hinblick auf das AVF sind daher präzise und aktuelle Karten notwendig. Wesentliche Fragestellungen – neben der Verlässlichkeit der eingehenden Sensorinformationen – ergeben sich aus den erhobenen Daten und deren Interpretation. Statistische Aussagen über die Sensordaten sind zu gewichten und als „erkannte Realität“ in die Kartendaten aufzunehmen. Hierbei stellen sich oft Widersprüche ein, die schwer durch automatisierte Verfahren zu entdecken sind.

Beispielsweise kann eine temporäre Fahrspurverlegung erst nach mehrfacher Befahrung durch die Flottenfahrzeuge vom Backend als korrektes Verhalten identifiziert werden. Findet sich ein solches Verhalten lediglich in einigen wenigen Trajektorien wieder, so könnte dies als Fehlverhalten von Verkehrsteilnehmern gesehen werden. Darüber hinaus führt eine nicht zu vermeidende zeitliche Verzögerung ebenfalls zu Fehlinterpretationen. Im genannten Beispiel können Baumaßnahmen

zwischenzeitlich beendet werden, und somit die ursprünglichen Fahrspuren wieder befahren werden. Eine erneute Kartenaktualisierung ist somit unumgänglich.

Es ist daher beinahe unmöglich, sämtliche Fallkonstellationen im Backend explizit zu berücksichtigen, um die richtigen Informationen aus den Sensordaten zu extrahieren. Anstelle eines vorgegebenen Regelkatalogs können Methoden des Machine-Learning (ML) helfen, erwartetes und abweichendes Verhalten zu trennen und Informationen in der Karte zu klassifizieren.

Unter künstlicher Intelligenz (KI, engl. Artificial Intelligence (AI)) versteht man grundsätzlich den Versuch, bestimmte Entscheidungsstrukturen des Menschen nachzubilden, d.h. ein möglichst eigenständiges Bearbeiten von Problemen durch das Computersystem zu erreichen. Einen großen Bereich der KI umfasst hierbei ML. Dieses Teilgebiet zeichnet sich wesentlich dadurch aus, dass ein System in der Lage ist, aus bekannten Fakten zu lernen und deren Regelwissen implizit abzubilden. Eine einfache Intelligenz kann dabei aus dem Abarbeiten von Entscheidungsfragen bestehen (sog. Regelbäume) oder dem Anwenden von einfachen und höherdimensionalen Regressionsmethoden für die Vorhersage von Daten. Selbstlernende Systeme hingegen erlernen aus einer Menge an Beispieldaten die dahinterliegenden Regeln und Modelle selbst und sind in der Lage, diese auf unbekannte Daten anzuwenden. Beispiele für ML sind Künstliche Neuronale Netze (KNN, engl. Artificial Neural Network (ANN)) oder hochdimensionale Regressionsverfahren (z.B. Support Vector Machines). KNNs mit einer hohen Anzahl an Zwischenstufen, d.h. Netze mit einer sehr „tiefen“ Architektur, werden heutzutage als Deep Learning bezeichnet. Allgemein wird zwischen überwachtem und unüberwachtem Lernverhalten unterschieden. Im überwachten Lernen wird neben einer Menge an Trainingsdaten auch die korrekte Klassifikation entsprechend der Aufgabenstellung vorgegeben (z.B. welches Straßenschild ein Bild darstellt). Unüberwachtes Lernen hingegen trennt die übergebenen Beispieldaten nach ihrer inneren Struktur auf verschiedene Klassen auf. Ein Anwender hat diese Daten nachträglich zu interpretieren. Ein Beispiel hierfür wäre die Aufteilung von Verkehrsteilnehmern auf Kamerabildern anhand ihrer Größe, ohne diese selbst zu erkennen (Fußgänger, PKW, LKW).

Deep-Learning-Verfahren sind heutzutage zu komplexen Aufgaben fähig. Dies umfasst Erkennungsaufgaben (Bildererkennung, Spracherkennung), das Generieren von Daten (Texterstellung, Bildgenerierung, Fahrtrajektorien) oder das Erkennen von Fehlern und Ausreißern in bekannten Systemen (Fault Detection, Predictive Maintenance, ...). Ihr größter Nachteil besteht im Bedarf großer Mengen an Trainingsdaten und (bestenfalls) ihrer korrekten Klassifikation. Das Erlernen von Verfahren durch das Fahrzeug und in den HAF-Karten erfordert ebenfalls eine hohe Menge realer Daten. Große Entwicklungen werden hierbei durch IT-Konzerne angetrieben, da sie

die benötigten Datenmengen gesammelt haben. Die Möglichkeiten des ML sind vielfältig und umfassen mittlerweile sämtliche Bereiche der automatisierten Datenverarbeitung.

Hochgenaue Karten für das automatisierte Fahren werden dabei heutzutage vornehmlich mit Messfahrzeugen, die mit hochwertiger Sensorik ausgestattet sind, erhoben und in (teil-) automatisierten Prozessen nachbearbeitet.

Im Projekt SAFARI sind diese hochgenauen Karten die Basis und werden von den Test-Fahrzeugen des Projekts für die Eigenlokalisierung herangezogen. Die Test-Fahrzeuge sollen nun ausgerüstet mit Serienkamertechnik und entsprechender Erkennungssoftware Abweichungen zwischen der hochgenauen digitalen Karte und der erfassten Umgebung erkennen. Die Abweichungen mehrerer Fahrzeuge werden in einem Backend ausgewertet und erlauben sowohl eine dynamische und zeitnahe Aktualisierung der Karten aller Fahrzeuge als auch Überprüfungs- und Kontrollmechanismen des digitalen Verkehrsmanagement. Dadurch ist man dem Stand der Technik entschieden einen Schritt voraus.

Für die Betrachtung von Karten ist es relevant, eine Fallunterscheidung zwischen verschiedenen Arten von Karten zu treffen. Die einfachste Variante einer digitalen Karte stellt die Navigations-Karte, die auch in Navigationsgeräten zum Einsatz kommt, dar. Diese ist allerdings maximal spurgenaue und enthält keine Informationen über die präzise Straßengeometrie, die zum automatisierten Fahren notwendig wären. Im Bereich Vermessungswesen gibt es hochgenaue Katasterkarten, die eine sehr präzise Darstellung der Realität vornehmen. In diesen wiederum fehlen Informationen zur Routenführung und zu Verkehrsregeln. Die HAF-Karte (HAF - Hochautomatisiertes Fahren) hingegen muss Informationen zu den Teilbereichen der Navigations-Karte, als auch Informationen, wie sie in der Kataster-Karte enthalten sind, haben. Darüber hinaus benötigt sie alle weiteren Informationen, die zur strategischen und taktischen Fahrplanung des Fahrzeugs erforderlich sind, z.B. Verkehrsregeln.

HAF-Karten werden dabei in eine räumliche, eine inhaltliche und eine zeitliche Unterteilung zerlegt. Technische Formate, die dieses umsetzen, sind z.B. der NDS-Standard oder das HERE HD Map Kartenformat.

Zu den NDS ist anzumerken, dass sie technisch die Möglichkeit bieten, HD-Karten umzusetzen. Insbesondere verwenden sie dafür den optionalen Lane-Building-Block, also eine zusätzliche Ebene für exakte Fahrspurgeometrie. In der Praxis (d.h. auf dem Markt verfügbare Navigationssysteme) werden diese Daten allerdings nicht bereitgestellt.

1.2 Szenarien

Zielsetzung des Projektes SAFARI ist die Entwicklung und praktische Erprobung des Zusammenspiels zwischen dem automatisierten und vernetzten Fahren und kooperativer Infrastruktur.

Die Entwicklung erfolgt anhand folgender Szenarien:

- Können die Fahrzeuge für die Selbstlokalisierung benötigte Landmarken aus dem Kartenmaterial extrahieren, mit der Wirklichkeit abgleichen und ggf. korrigieren?
- Kann die Lage der Lichtsignalanlagen (bzw. der Signalgeber) aus dem Kartenmaterial extrahiert werden und damit der Signalgeber und die aktuelle Signalfarbe sicherer sensorbasiert erkannt werden? Wie können V2X-Anwendungen die LSA-Erkennung weiter verbessern?
- Wie gut werden Baustellen erkannt und können die von den Fahrzeugen an ein Backend gelieferten Daten dazu verwendet werden, die Aktualität der Baustelleninformation in der Karte bzw. Verstöße gegenüber den Auflagen der Anordnung einer Baustelle (Verkehrssicherung laut Regelplan) zu überprüfen?
- Können die freien Parkplätze durch einen Abgleich von in der Karte gekennzeichneten Bereichen, die ein Parken am Fahrbahnrand erlauben oder markierte Parkplätze repräsentieren, mit dem belegten und dem tatsächlich freien „Freiraum“ identifiziert werden?
- Wie gut können Abweichungen von der gemäß Karte erwarteten Situation oder im Straßenraum auftretende Gefährdungen erkannt werden (vom verdrehten Verkehrszeichen bis zum 2. Reihe Parker)?

Was auf Fahrzeugebene aus den Daten eines Fahrzeuges erkannt werden kann, wird durch die Auswertung der Daten mehrerer Fahrzeuge im SAFARI-Backend weiter verbessert. Die Ergebnisse der Änderungsdetektion werden hier vereinfacht Korrekturen genannt. Sie können anschließend durch Mitarbeiter der Verwaltung bearbeitet und bestätigt, und dann in den Kartendaten des Landes Berlin aktualisiert werden. In der Projektlaufzeit erhofft sich das Land Berlin bereits Erkenntnisse in Richtung einer zukünftig automatisierten Anpassung des Kartenmaterials.

Auswertungen im Backend erlauben zudem, die Einhaltung der geplanten Fahrlinien anhand der Trajektorien zu erkennen (Fahrbahnverläufe). Mit entsprechenden Auswertungen sollen Ursachen für unerwartete Fahrmanöver und eine Kartierung der Ursachen („Schlaglochdetektor“) identifiziert werden.

1.3 Zielsetzung

Das vorliegende Dokument führt die Ergebnisse der einzelnen APs in einer übersichtlichen Form zusammen. Die Zusammenfassung beruht auf den Projektergebnisberichten (Deliverables) und den Schlussberichten der Partner.

2 Wissenschaftlich-technische Ergebnisse und wesentliche Ereignisse

2.1 AP 1 Projektmanagement und Ergebnisverbreitung

Der Erfolg in Forschung und Entwicklung in inhaltlich anspruchsvollen Verbundprojekten wie dem von SAFARI hängt in hohem Maße davon ab, ob und wie es gelingt, das Projekt als zielorientierten Prozess zu gestalten. Hierzu bedarf es neben inhaltlicher Kompetenz einer hohen sozialen und organisatorischen Kompetenz. Der Gesamtprojektkoordination und dem Projektleiter kommt dabei eine Schlüsselfunktion zu.

SenUVK war als einer der in Berlin für die zukünftige Anwendung der Erkenntnisse aus SAFARI hauptverantwortlichen Partner und Federführer des Konsortiums. Zur inhaltlichen Gesamtprojektleitung bzw. -koordination (einschließlich Dissemination) wurde von BLIC als Unterauftragnehmer ein erfahrener Projektleiter bzw. -koordinator gestellt. Diese Dienstleistung wurde von allen Partnern beauftragt.

Der Projektleiter hat die Durchführung der F&E-Arbeiten mit dem Projektteam und den Projektgremien in enger Abstimmung mit dem Federführer so geleitet, dass die Gesamtprojektabwicklung jederzeit und kontinuierlich gewährleistet wurde.

Dabei erfüllte das Change Management eine wichtige Rolle, in dem nötige Änderungen rechtzeitig erkannt und vorbereitet wurden, sodass die inhaltlichen Gesamtprojektziele weiterhin erreichbar blieben.

Dies betraf vor allem den Themenkomplex V2X, der durch ursprünglich nicht absehbare, langwierige Genehmigungsprozesse bei Lichtsignalanlagen in starken Verzug geriet, mit der Folge, dass das Projekt am Ende seiner ursprünglich geplanten Laufzeit ohne Ergebnis für V2X geblieben wäre. Die Projektleitung konnte dem entgegenwirken, indem sie rechtzeitig einen Konsens zwischen den Projektpartnern zur Laufzeitverlängerung vorbereitete und beim Projektträger eine Laufzeitverlängerung um 6 Monate erreichte.

Das Verbundprojekt soll neben den formalen Berichten, die eher nach innen und gegenüber dem Projektträger wirken, auch eine angemessene Außenwirkung entfalten.

Neben dem Berichtswesen wurde vor allem die Ergebnisverbreitung und Außenwirkung koordiniert und durchgeführt.

Der Projektleiter hat die Durchführung der F&E-Arbeiten mit dem Projektteam und den Projektgremien in enger Abstimmung mit dem Federführer so geleitet, dass die antragskonforme und kostengerechte Gesamtprojektabwicklung innerhalb einer Verlängerung von einem halben Jahr gewährleistet war.

Ziel war die Einhaltung der Berichtspflichten, die Abstimmung mit Dritten und die öffentlichkeitswirksame Aufbereitung und Darstellung von Gesamtprojektergebnissen.

2.2 AP 2 Gesamtkonzeption

2.2.1 AP 2.1 Analyse Ist-Zustand und Randbedingungen

SenUVK hat als für die Gesamtkonzeption verantwortlicher Partner die Dokumentation des Standes der Technik initiiert und die Zuarbeiten der einzelnen Partner in einer konsolidierten Beschreibung zusammengeführt. Es wurde der Ist-Zustand und die Randbedingungen in Bezug auf die Umfeldwahrnehmung und die vorgesehenen Sensoriken, das Kommunikationsmanagement und die Selbstaktualisierende Karte sowie die zugrunde liegenden Bestandssysteme der Verwaltung beschrieben. Die Bestandssysteme sind im Folgenden nur dort detailliert erläutert, wo es für das Verständnis der Beschreibung des Ergebnisses notwendig ist.

2.2.2 AP 2.2 Anforderungsanalyse und Systemkonzeption

2.2.2.1 Use Case Definition und Ableitung der Architektur

Für die in der Vorhabenbeschreibung benannten Szenarien oder auch Use Cases wurden entsprechende Anwendungsfälle definiert und die Akteure und Beziehungen zwischen ihnen (Datenflüsse) identifiziert.

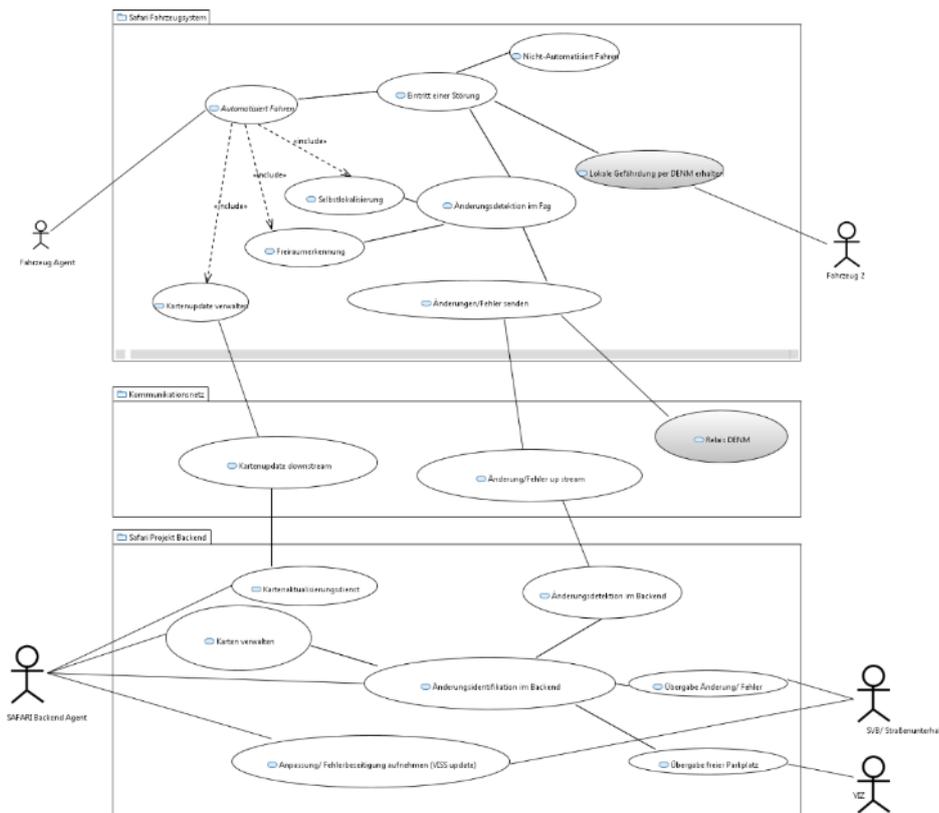


Abbildung 2-1: Use Case Übersicht

Ausgehend von den entwickelten Use Cases wurde eine Systemarchitektur für die drei Ebenen Fahrzeug, Kommunikation und Zentralen entworfen und die Anforderungen an die Umsetzung in einem Rahmenlastenheft festgehalten.

Die **Fahrzeugebene** repräsentiert die Verkehrsteilnehmer und Kunden der entwickelten Dienste. Innerhalb des Vorhabens werden jedoch nur Versuchsträger der Forschungspartner eingesetzt.

- Forschungsfahrzeuge mit spezialisierter Sensorik (Laserscanner, 3D-Vision (360°Vision mit Stereosicht-Bereichen) und hochgenauer landmarkenbasierter Selbstlokalisierung, die Fahrzeuge der FU Berlin werden zusätzlich mit Monokameras ausgerüstet
Serienfahrzeuge mit Monokameras im Prototypenstadium und Selbstlokalisierung über D-GNSS und Landmarkenerkennung
- Linienbusse der BVG wurden mit einer Smartphone-Anwendung ausgestattet, die für eine Selbstlokalisierung die GPS-Ortung des Smartphones verwendet.

Die **Kommunikationsebene** ist aufgeteilt in die Vehicle2Infrastructure (V2I)-Kommunikation der Verkehrsinfrastruktur vor Ort (hier: Lichtsignalanlagen) und die öffentliche vorhandene sowie neue

testweise errichtete 4,5 G Kommunikationsinfrastruktur vor Ort (LTE Advanced bzw. LTE advanced plus mit Cellular V2X, falls Komponenten vor Ende der Projektlaufzeit verfügbar sind).

Die Lichtsignalanlagen des Testfelds (LSA) werden dabei um Roadside Units ergänzt und für folgende V2X-Anwendungen ertüchtigt:

- Signal Phase and Timing (SPaT) mit laufend aktualisierten Prognosen der restlichen Laufzeiten der aktuellen Signalphase und
- Topologische Meldungen des Kreuzungsaufbaus (MAP)

Selbstverständlich müssen die Fahrzeuge selbständig die Lichtsignalanlagen erkennen. Die im Fahrzeug aufgezeichneten Daten (Sensorik plus empfangene Signaldaten aus SPAT/MAP) werden im Backend mit den online Signalisierungsdaten aus dem Verkehrsrechner verglichen.

Darüber hinaus soll die Anwendung der Kommunikationsinfrastruktur für Mobile Edge Computing (MEC) Anwendungen untersucht werden.

In der **Zentralenebene** werden sowohl das SAFARI-Backend als auch die Bestandssysteme der für das Verkehrsmanagement zuständigen Verwaltung zusammengefasst.

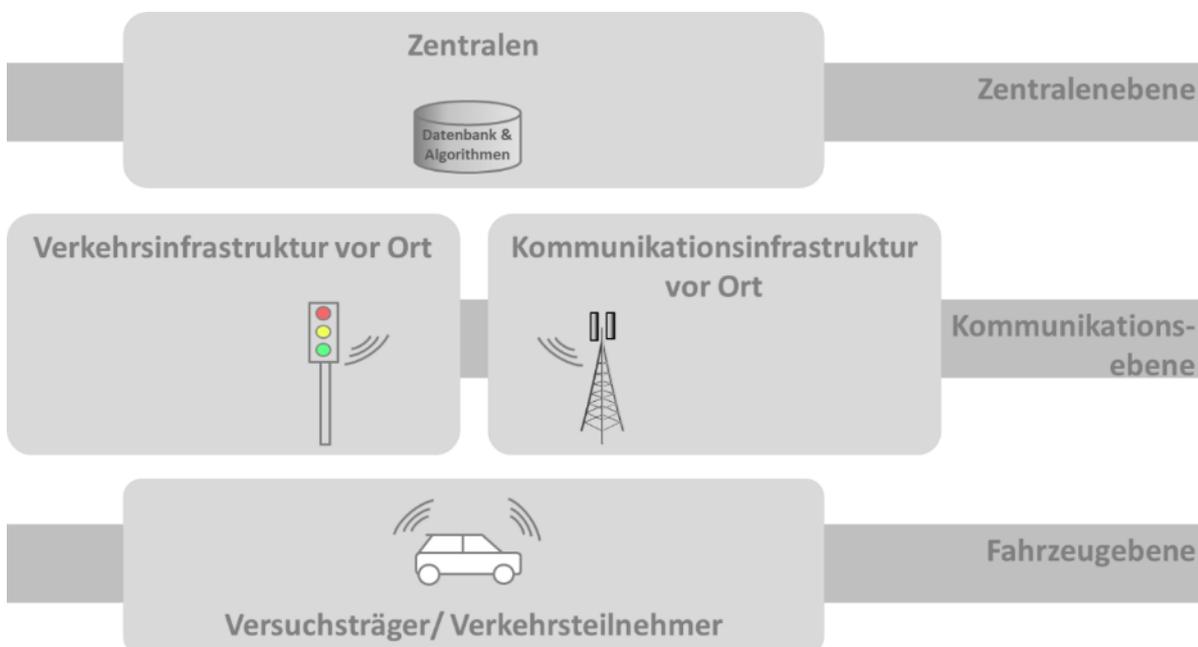


Abbildung 2-2: Ebenen der Systemarchitektur

Die Anforderungen anschließend für die wesentlichen Prozessschritte spezifiziert. Auf den als Versuchsträgern (VT) bezeichneten Fahrzeugen werden folgende Prozesse umgesetzt:

- Aufbereitung der vorhandenen Kartendaten zur Verwendung in den jeweiligen Fahrzeugen
- Die VT fahren eine vordefinierte Strecke im Versuchsgebiet ab.
- Bei der Fahrt durch das Testfeld werden die Objekte mit der im VT verfügbaren Sensorik detektiert.
- Die Daten der Sensorik werden zusammen mit den Odometrie-Daten, GNSS und anderen Eingangsdaten der Umfeldwahrnehmung übergeben.
- Die Umfeldwahrnehmung trackt, erkennt und loggt Objekte basierend auf der jeweiligen Selbstlokalisierung.
- Die entstehenden Daten werden entsprechend gekennzeichnet, damit sie zur Änderungsdetektion im Fahrzeug und im Backend auch nach Sensorik getrennt verwendet werden können.
- Die Objektdaten werden an die Vorverarbeitung übergeben, um die Trackingrate zu vereinheitlichen und (je nach VT) eine Fusion der Daten durchzuführen.
- Anschließend wird die Änderungsdetektion durchlaufen, die aus einem Vergleich der Objektdaten mit den Kartendaten beruht.
- Die Objektdaten werden an das Kommunikationsmanagement des VT übergeben, das über das Aussenden der Objektdaten auch für den Rückkanal (Kartendatenaktualisierung durch das Backend) und den Empfang und die Dekodierung der SPaT/MAP-Meldungen der LSA dient.

Die beschriebene Kette stellt den Idealzustand dar. Sie wird nicht von allen VT realisiert werden. Einzelne VT werden nur einen Teil der Kette durchlaufen bzw. nur eine Aufzeichnung der Objektdaten umsetzen (offline Änderungsdetektion).

Die wesentlichen Prozessschritte und Komponenten im Backend sind:

- In der Eingangsstufe werden im Kartenkonverter die vorhandenen Kartendaten zur Verwendung im Backend aufbereitet und in der Kartendatenbank abgelegt.
- In der Klassifikation werden die eingehenden Objektdaten einer ersten Prüfung unterzogen und anschließend zum einen in der Objektdatenbank abgelegt und zum anderen einem Stream-Prozess zur Identifikation von potenziellen Gefährdungen unterzogen.
- Auch im Backend beruht die Änderungsdetektion auf einem Vergleich der Objektdaten mit den Kartendaten.

- Für die Änderungsdetektion wird eine Umgebung bereitgestellt, in der viele verschiedene, spezialisierte Algorithmen sowohl schnell erkennbare als auch nur aus Langzeitbeobachtungen erzielbare Änderungen identifizieren.
- Die erkannten Änderungen werden in der Ergebnisdatenbank der Ausgangsstufe ablegt. Die Ergebnisse der verschiedenen Algorithmen werden markiert (Evaluationsmessage: Objektdaten und welche Sensoren aus welchem Zeitraum zum Ergebnis beigetragen haben).
- Die Objektdaten werden über entsprechende Konverter in passenden Formaten zur Überprüfung durch VISS-Mitarbeiter/ VMS-Nutzer (BA Reinickendorf/ VLB) ausgegeben.
- Die Weitergabe der aufbereiteten Daten an die Fahrzeuge erfolgt zum Zeitpunkt „Start Datenakquise“ proprietär/individuell.

Kartendatenaktualisierungen zu den Fahrzeugen/ Versuchsträgern können nach erfolgter Freigabe erkannter Änderungen durch VISS-Mitarbeiter mit einer neuen Datenübernahme erfolgen.

Entlang der Prozesskette wurden die jeweiligen Anforderungen und Schnittstellen definiert. Grundsätzlich wird für die Datenlieferung von den VT zum Backend auf die frei zugängliche Protocol-Buffers „protobuf“ Technologie von Google zur Gewährleistung einer einheitlichen Verarbeitung unter den Komponenten des Systems zurückgegriffen.

Die Änderungsdetektion ist somit die zentrale Funktion in SAFARI. Sie basiert auf der Objekterkennung der verschiedenen VT-Sensoriken. Zu Beginn des Design-Prozesses wurde deshalb sichergestellt, dass die verschiedenen Szenarien sowohl auf dem einzelnen Versuchsträger als auch im Backend durch mindestens einen Projektpartner abgedeckt sind:

Tabelle 2-1: Objekterkennung in SAFARI und Verantwortliche

Szenarien	FUB	FOKUS	DCAITI	HELLA Aglaia	IAV	
Landmarken	VT		VT	VT		
LSA	VT			VT	VT	
Parken	VT		VT	VT		Parkstreifen
Baustellen	VT	App	VT	VT		
Abweichung & Gefährdung						
Verkehrszeichen	VT	App	VT	VT	VT	

Markierung	VT	App	VT	VT		
Straßenoberfläche						Oberflächen-auffälligkeiten
Spureinhaltung	VT			VT		Auswertung der Fahrspuren im BE
2. Reihe Parker	VT			VT		

Anmerkungen:

VT bedeutet, dass dieser Versuchsträger nur zu diesem Szenario gehörende Objekte erkennt und in das Backend sendet. Z.B. erkennt der IAV-Versuchsträger LSA V2X Meldungen und Verkehrszeichen auf dem Fahrzeug und überträgt nur diese Objekte in das Backend.

App bedeutet, dass in mehreren Bussen der BT/BVG Smartphones mit der FOKUS-Software zur Objekterkennung eingesetzt werden. Die VT von FOKUS werden mit der Sensorik der DCAITI ausgestattet.

Tabelle 2-2: Änderungsdetektion in SAFARI und Verantwortliche

Szenarien	FUB	FOKUS	DCAITI	HELLA Aglaia	IAV	
Landmarken	VT		VT/ BE	-	BE	
LSA	VT			-	VT/ BE	
Parken	VT			-	BE	Parkstreifen
Baustellen	VT	BE	VT/ BE	-	BE	
Abweichung & Gefährdung						
Verkehrszeichen	VT	BE		-	VT/ BE	
Markierung	VT			-	BE	
Straßenoberfläche	VT			-	BE	Oberflächen-auffälligkeiten
Spureinhaltung		BE		-	BE	Auswertung der Fahrspuren im BE
2. Reihe Parker	VT			-	BE	

Anmerkungen:

VT bedeutet, dass auf diesem Versuchsträger auch eine Änderungsdetektion im Fahrzeug stattfindet, unabhängig von einer zusätzlichen Verwendung für eine Änderungsdetektion im Backend.

Nur BE bedeutet, dass mit diesen Fahrzeugen erhobene Daten nur im Backend für die Änderungsdetektion verwendet werden.

Die Daten der HELLA Aglaia Versuchsträger sollen nur im Backend ausgewertet werden (Algorithmen IAV-Änderungsdetektion).

2.2.2.2 Datenanforderungen und VISS-Daten Aufbereitung

Die VISS-Geschäftsstelle ergänzt zu den Objekten des Objektkatalogs (Stand August 2017) folgende Informationen in den VISS-Daten für das Testfeld:

- Höheninformation für Überkopf-Signalgeber (für Durchfahrthöhe relevant, andere Ampelelemente sind derzeit nicht vorgesehen) und Verkehrszeichen (bisher wurde regelkonforme Anbringung in Standardhöhe angenommen).
- Parkerlaubnisbereiche als Abgrenzung zwischen „Parken baulich getrennt“, „Parken markiert“ und „Parken nicht verboten“ und Ein- und Ausfahrten sowie eine abgeschätzte Anzahl der möglichen Parkplätze.

Durch SAFARI-Partner wurden aus den im FIS-Broker zur Verfügung gestellten Daten Lichtmasten und Baumstämme ergänzt und Fahrspuren gebildet.

Für neue Objekte werden entsprechende Layer und ggf. Attribute in SAFARI Ergebnisdatenbank angelegt.

2.2.2.3 Zuordnung der Objekte

Die Objektbezeichner in SAFARI (SAFARI-Klassifikation) wurden so gewählt, dass durch die Sensorik erkennbare Objekte der Verkehrsinfrastruktur abgebildet werden können. Sie müssen für die Änderungsdetektion den Objektbezeichnern aus der Klassifikation der Senatskarte zugeordnet werden. Dabei sind bezüglich des Objektkataloges für die Anwendung in SAFARI folgende Besonderheiten zu beachten:

- Fahrbahnmarkierung sind unterteilt in drei Shapes mit unterschiedlicher Geometrie:
 - Piktogramm (mit Piktogramm-Nr.)
 - Linie (z.B. Leitlinie Z340 oder Busspur)
 - Fläche (z.B. Fußgängerüberweg Z 293)
 - Fahrbahnfläche ist als Gesamtfläche ohne Richtungsinformation verzeichnet, wenn keine Fahrbahntrennungen vorliegen.
- Fahrbahnsegmente werden durch andere flächige Objekte wie Kanaldeckel oder Änderungen des Oberflächenmaterials zerschnitten, eine befahrbare Fläche muss teilweise rekonstruiert werden.

- Baustellen werden nur durch Polygone abgebildet.
- LSA-Masten enthalten keine Angaben zu Signalgebern (Art, Ausrichtung, Signalbild, Höhe etc.).
- Mehrere Verkehrszeichen an einem Mast werden nur nummeriert, erhalten keine eigene Position.
- Kombinierte Licht- und Ampelmasten sind in zwei „Katalogen“ aufgeführt.
- Lichtmasten mit zwei Fußpunkten weisen nur eine mittlere Position auf.
- Schäden der Straßenoberfläche sind derzeit nicht im VISS abgelegt.
- Abweichende Spurbreiten, Krümmung, Spuranzahl sind derzeit nicht im VISS abgelegt.

Zudem sind die Daten der Kreuzungen im Testgebiet zu überprüfen (Abgleich VLB-Daten und SPAT/MAP-Anforderungen, Signalgeber erhält Objekt-ID).

2.2.3 AP 2.3 Technische Koordinierung

Der regelmäßige Abgleich zwischen geplanter Umsetzung und tatsächlicher Umsetzung wurde auch in einer Überarbeitung des Rahmenlastenheftes (Stand Objekterkennung und Stand Veränderungsdetektion) und den Anpassungen der Schnittstelle zwischen den VT und dem Backend dokumentiert. Gegen Projektende wurde die Gegenüberstellung der geplanten und umgesetzten Use Cases nochmals aktualisiert (siehe Abschnitt 3.1.2 und 3.1.3).

Auch die Abstimmungen innerhalb des Konsortiums zur Verlängerung der Projektlaufzeit verlangten eine detaillierte Abgrenzung zwischen bereits umgesetzten Ergebnissen und noch in der Verlängerung zu leistenden Aufgaben (z.B. Bewertung der Daten durch die VISS-Geschäftsstelle, Umsetzung weiterer RSU und Abstimmung mit Herstellern und assoziierten Partner, siehe auch Abschnitt 3.1).

2.3 AP 3 Umfeldwahrnehmung

2.3.1 AP 3.1 Freiraumerkennung

2.3.1.1 Kamerabasierte Erkennungsalgorithmik

Für das Projekt wurden verschiedene Erkennungsverfahren aus Kamerabildern verwendet. Zunächst kam die von der HELLA Aglaia entwickelte Fahrspurerkennung zum Einsatz. Da diese als fertiges Produkt vorhanden war und ohne Anpassungen verwendet wurde wird hier nicht näher darauf eingegangen.

Zwei Verfahren, die im SAFARI-Kontext entwickelt bzw. angepasst wurden, sind die Freiraumerkennung (FRE) und die Objekterkennung.

Das Ziel der FRE ist die Bestimmung des vom Fahrzeug befahrbaren Bereiches. Durch die FRE werden sowohl Verkehrsteilnehmer wie Fahrzeuge, Fußgänger oder Rad- und Motorradfahrer, als auch angrenzende Hindernisse wie Bordsteine, Pylonen, Baustellengeländer und –baken gekennzeichnet. Als Ergebnis der FRE werden mehrere Polylinien erzeugt, die die Übergänge vom befahrbaren Bereich zu den angrenzenden Objekten markieren, und die Fläche vom Fahrzeug bis zu den genannten Übergängen bestimmt.

Die grundlegende Technologie hinter der FRE ist eine auf einem neuronalen Netzwerk beruhende semantische Segmentierung des Bildes. Dabei wird jedem Pixel des Bildes eine der semantischen Klassen Straße, Gehweg, Fahrzeug, ungeschützter Verkehrsteilnehmer (Fußgänger, Fahrradfahrer, Motorradfahrer, ...) oder Rest zugeordnet. In Abbildung ist das Ergebnis einer solchen semantischen Segmentierung dargestellt.



Abbildung 2-3: Aufnahme aus dem Versuchsgebiet. Links: Originalbild, Rechts: Ergebnis aus der semantischen Segmentierung

Auf Basis der pixelweisen Semantischen Segmentierung des Bildes wurde in einem zweiten Schritt der befahrbare Freiraum ermittelt. Dazu wurde entlang radialer Suchlinien ausgehend vom eigenen Fahrzeug Übergänge von der Straßenklasse zu anderen semantischen Klassen im Bild der Semantischen Segmentierung bestimmt. Zusammen genommen bilden diese Übergangspunkte ein Polygon, welches die Grenze des befahrbaren Bereichs beschreibt. Mit Hilfe der Kamera-Kalibrierung und der Annahme einer flachen Umgebung kann das Polygon in Weltkoordinaten, also Koordinaten mit metrischen Entfernungen relativ zum Fahrzeug, projiziert werden. Damit hat man eine Bestimmung des befahrbaren Freiraums um das Fahrzeug erreicht (vgl. Abbildung).

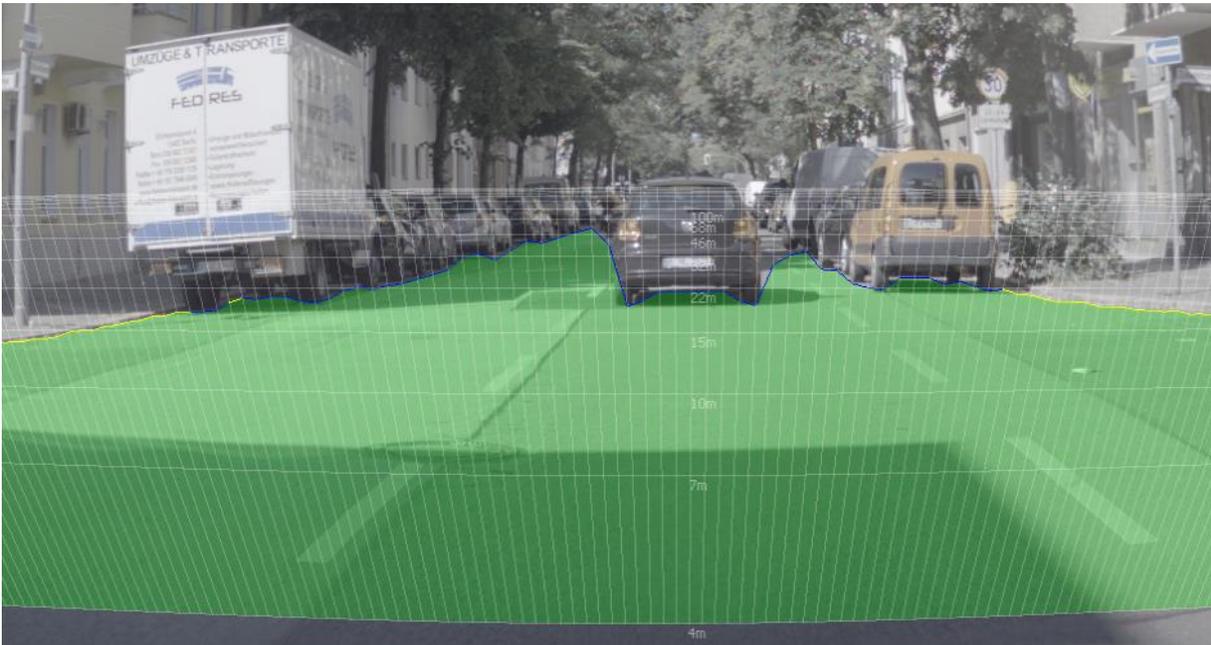


Abbildung 2-4: Visualisierung der Suchlinien mit der aus der Kamera-Kalibrierung errechneten relativen Entfernung zum Fahrzeug.

Die FRE wird als ein Input für die kamerabasierte Selbstlokalisierung verwendet. Darüber hinaus gibt es dafür aber auch eigenständige Anwendungen. So kann sie dazu verwendet werden, um freie Parklücken (Abbildung) oder Zweite-Reihe Parker zu detektieren (Abbildung).

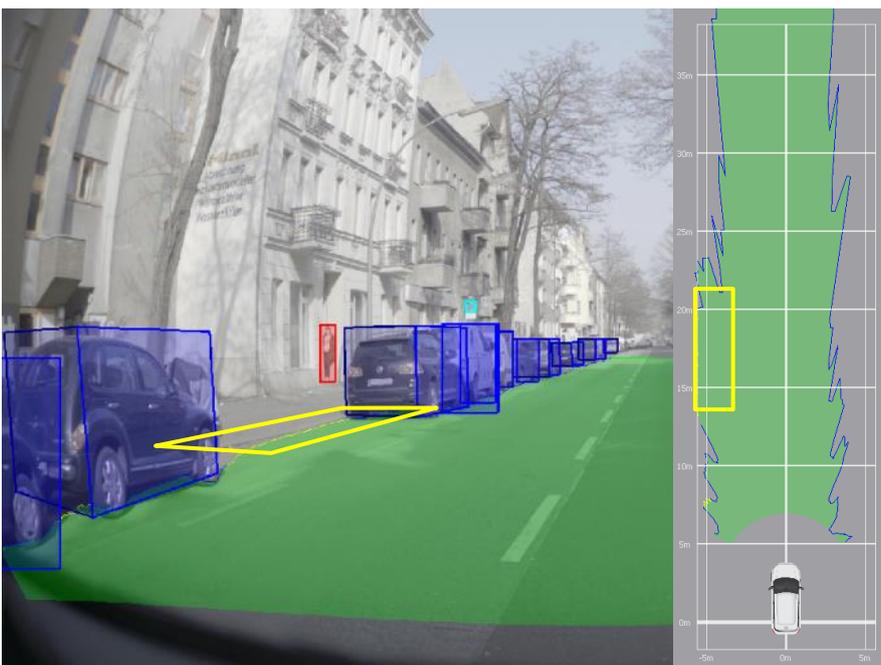


Abbildung 2-5: Parklücke zwischen Fahrzeugen, erkannt als Zone von Straße-Gehweg-Übergang (gelbe Linie) zwischen zwei Zonen mit Straße-Fahrzeug-Übergang.

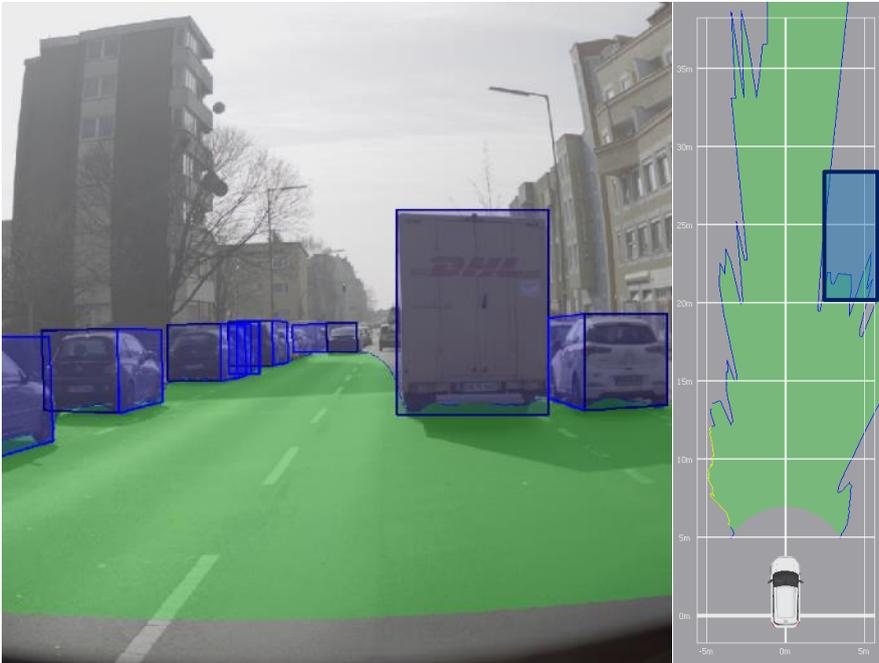


Abbildung 2-6: Die Freiraumerkennung detektiert ein Fahrzeug als Hindernis mitten auf der Fahrs pur.

Das Ziel des zweiten Detektionsmoduls, der Objekterkennung, ist die Detektion und Lokalisierung von Objekten, welche im Abgleich mit vorhandenem Kartenmaterial eine präzise Selbstverortung ermöglichen. Dazu werden zunächst aus dem Bild mit Hilfe eines neuronalen Netzes Bounding Boxes (das sind zwei-dimensionale Rechtecke, die das jeweilige Objekt eng umranden) die relevanten Objekte bestimmt. Anschließend werden in einem zweiten Schritt die detektierten Verkehrsschilder und Ampeln noch einmal feiner klassifiziert, um verschiedene Arten von Verkehrsschildern und Ampelphasen zu unterscheiden. Abschließend werden die erkannten Objekte über aufeinander folgende Bilder getrackt, das heißt gleiche Objekte werden in konsekutiven Bildern miteinander identifiziert, und mit Hilfe der Kamerakalibrierung relativ zum eigenen Fahrzeug verortet. Derzeit erkannte Klassen sind Verkehrszeichen, Ampeln, Kanaldeckel, Baustellenbaken und Baustellengeländer.

Wie beim FRE ist die Objekterkennung einerseits ein Input für die Lokalisierung, hat aber auch viele eigenständige Anwendungen. Als Beispiel sei die Baustellenerkennung genannt (vgl. Abbildung), die dadurch erfolgt, dass Objekte wie Baustellenbaken und Zäune detektiert werden.

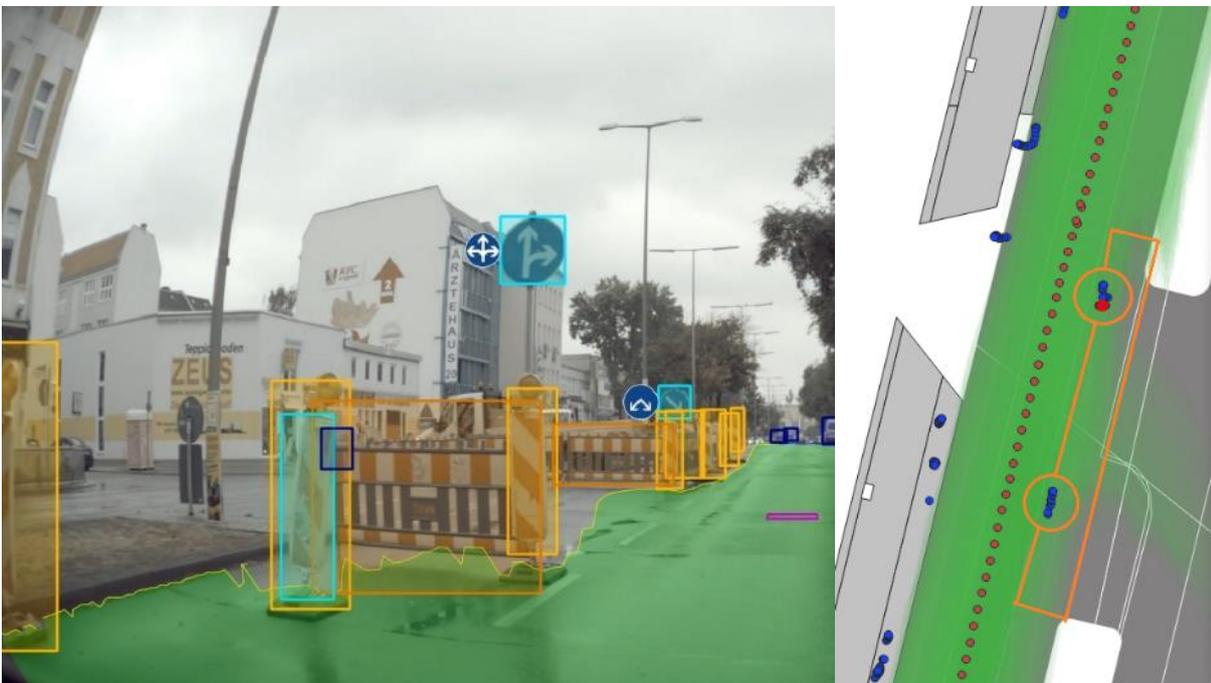


Abbildung 2-7: Erkennung der Baustellenbaken und -zäune als extra antrainierte Klassen (links). Ergebnis aus der koordinierten Datenakquise, wo Freiraum und Baustellenbaken zu erkennen sind.

2.3.1.2 3D-Vision basierte Freiraumerkennung

Die Hauptarbeiten und Ergebnisse des DCAITI im Projekt liegen im AP3 der Umfeldwahrnehmung und Selbstlokalisierung. Dazu wurde ein neuartiger 3D-Vision Sensors entwickelt, der durch ein KI-basiertes Softwareframework die Objekt- und Freiraumerkennung sowie die Lokalisierung realisiert.

Die Freiraumerkennung bestimmt anhand der verarbeiteten Sensordaten den befahrbaren Bereich des Verkehrsraumes. Dazu wird aus Echtzeitgründen eine Auswertung der 3D-Daten der LiDAR-Sensoren genutzt.



Abbildung 2-8: Der aus den 32-Strahl-LiDAR Daten mittels optimierten Algorithmus erkannte, absolute Freiraum (grüne Polygonlinie).

Zur Erkennung von Verkehrsteilnehmern, Verkehrsschildern, Baken und Absperrschranken im Fahrbahnbereich kommen Deep Learning Verfahren zum Einsatz. Die Detektion von Objekten im Verkehrsraum erfolgt in mehreren Phasen, die durch eine Sensorverarbeitungseinheit (SVE) und eine Perception Unit (PU) realisiert werden. Die Datenübertragung zwischen der Sensorverarbeitungseinheit (SVE) des 3D Vision Sensors und der Perception Unit (PU) erfolgt über eine TCP/IP-basierte Schnittstelle mit einer effizienten Serialisierung der zu übertragenden Daten. Das Umfeldmodell (UMF) dient der Aggregation, Fusion, Sortierung, Änderungsdetektion und Weiterverarbeitung der durch die einzelnen Sensorsysteme und Verfahren bestimmten Perzeptionsentitäten.

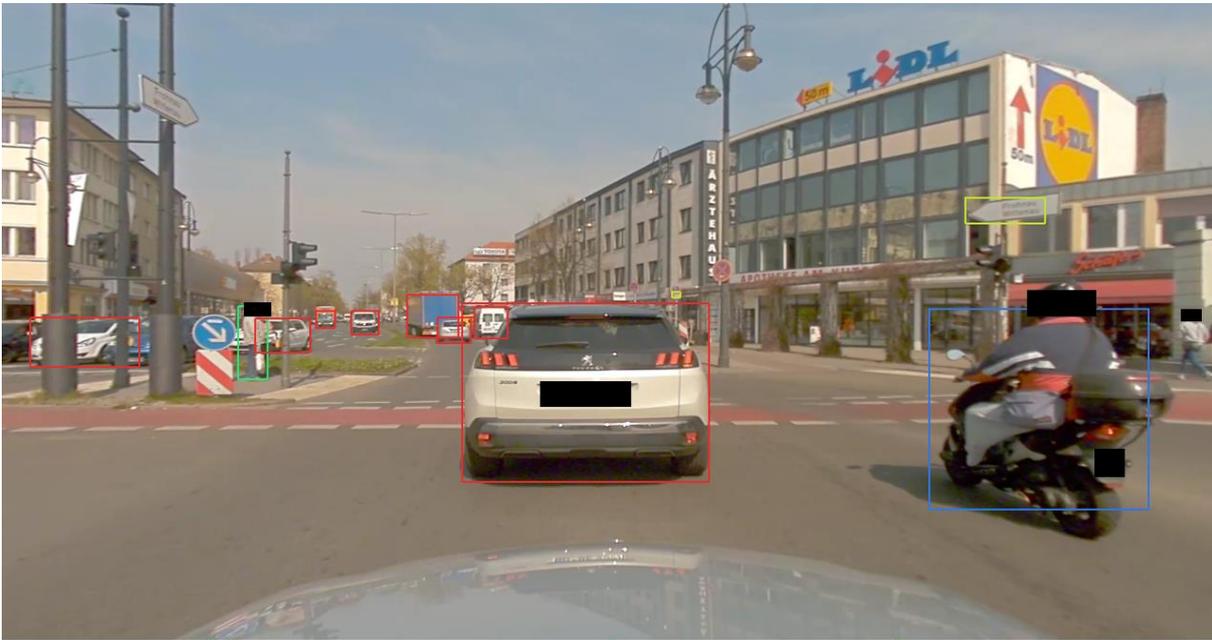


Abbildung 2-9: Erkennung und Klassifikation von dynamischen Objekten durch die Anwendung eines Deep Learning Netzwerks Car (rot), Bicycle (blau), Pedestrian (grün).

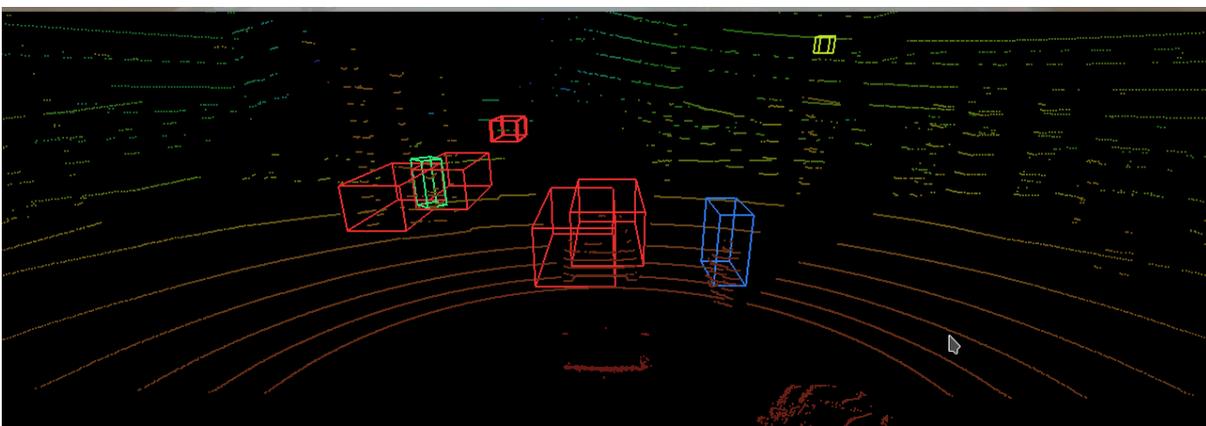


Abbildung 2-10: Die Projektion der 2D-Bounding Boxen in die 3D-LiDAR-Daten realisiert einen sehr einfachen 3D-Box-Detektor.

Unter normalen Tageslichtverhältnissen arbeitet die Objektdetektion mittels der Deep Learning Netze sehr robust und genau. Ein entscheidender Umwelteinfluss, der erst durch die Feldtests im Projekt deutlich wurde, ist die Verunreinigung der Sensoren z.B. durch Insektenrückstände. Diese betrifft sowohl die Kameras als auch die LiDARs. Bei mäßigem Regen oder starkem Sonnenlicht werden weder die Kamera- noch die LiDAR-Detektion maßgeblich gestört.

2.3.1.3 LiDAR-basierte Freiraumerkennung

Um Freiräume auf Basis von LiDAR Daten zu erkennen, wurden zwei verschiedene Typen von LiDAR Sensoren eingesetzt: ein einzelner 64-strahliger 360° Rotationslaserscanner von Velodyne HDL64E-S2 und ein für Fahrzeuge ausgelegtes Laserscanner-Array von Ibeo, bestehend aus sechs Scannern und einer Datenverarbeitungseinheit.

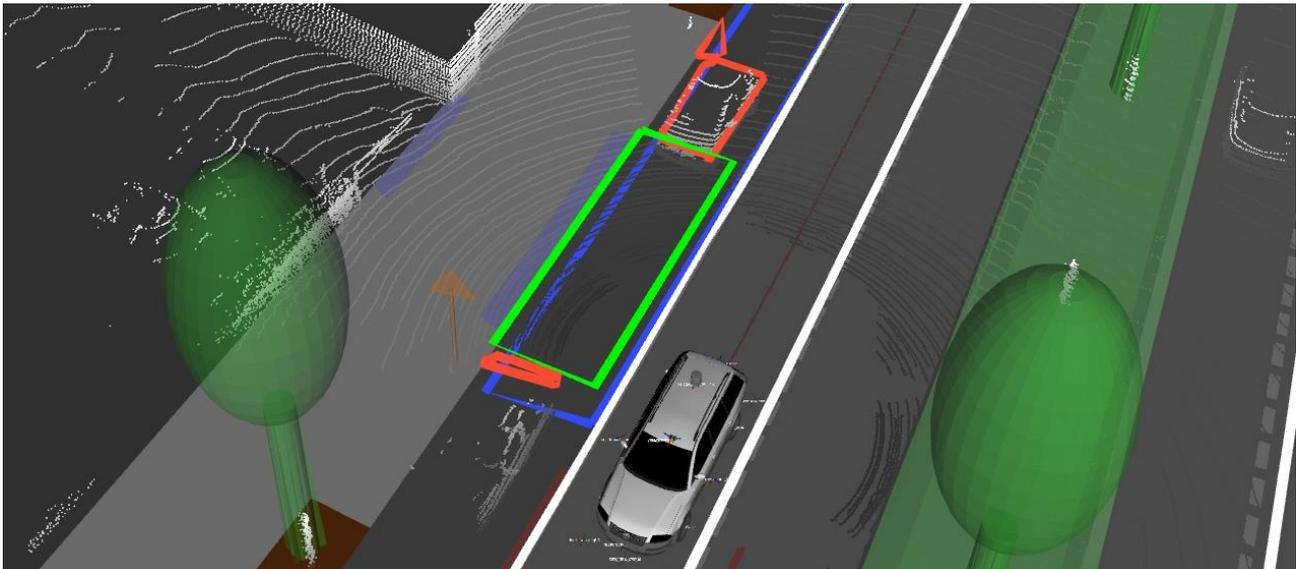


Abbildung 2-11 : Erkennung von der Belegung der Parkplätze mithilfe LiDAR Sensoren (Ibeo-Laserscanner-Array)

Blau markierte Linien: Parkbereich, grünes Rechteck: freier Parkplatz, rotes Rechteck: belegter Parkplatz

Aus den Daten des Rotationsscanners wurde mit einem einfachen Ansatz ein Freiraumpolygon der direkten Umgebung des Fahrzeugs erstellt. Der Verschnitt dieses Polygons mit der VISS-Karte stellte sich aufgrund seiner komplexen Form als zu rechenintensiv für eine online Verarbeitung auf dem Fahrzeug heraus. Mit Hilfe dieses Freiraumpolygons konnte jedoch auf dem SAFARI-Backend eine Parkplatzdetektion demonstriert werden.

Das Ibeo-Laserscanner-Array beinhaltet eine Recheneinheit, die die Daten der sechs im Fahrzeug verbauten Scanner fusioniert und zusätzlich eine Extraktion von klassifizierten Objekten vornimmt. Mit Hilfe dieser Ibeo-Objekte konnte eine Version der Parkplatzdetektion implementiert werden, die in Echtzeit auf dem Fahrzeug lauffähig ist. Dabei ist die vom Ibeo-System vorgenommene Klassifizierung nur bedingt hilfreich, da eine Klassifizierung nur von bewegten Objekten erfolgt. Fahrzeuge auf Parkflächen bewegen sich meist nicht und werden somit meist als die Klasse unbekannt gekennzeichnet. Dennoch können die Umriss der Ibeo-Objekte genutzt werden, um

während der Vorbeifahrt mittels Verschnittes mit den Parkbereich-Polygonen aus der VISS-Karte festzustellen, welche Bereichsabschnitte mit Objekten wie Fahrzeugen o.ä. belegt sind.

Die Detektion von Baustellen und 2. Reihe parkenden Fahrzeugen wurde ebenfalls auf Basis der Ibeo-Objekte entwickelt. Die Umriss der Ibeo-Objekte werden hierbei mit den Fahrbahn-Polygonen aus der VISS-Karte verschnitten. Da Fahrspurinformationen in der VISS-Karte fehlen, kann über den blockierten Bereich von Fahrspuren einer Fahrbahn keine Aussage getroffen werden.

Im Unterschied zur Parkplatzdetektion muss ein Tracking des blockierten Bereiches vorgenommen werden, um sicherzustellen, ob der entsprechende Bereich durch ein stehendes Objekt blockiert ist. Anders als in Parkbereichen, wird zunächst einmal angenommen, dass Objekte auf der Fahrbahn in Bewegung sind. Nur wenn nach längerer Beobachtungszeit der beobachtete Bereich weiterhin belegt ist bzw. das beobachtete Objekt unbewegt ist, kann eine Aussage darüber getroffen werden, ob ein Bereich durch ein Objekt blockiert wird oder nicht.

Ein einzelnes Fahrzeug kann dies auch nur eingeschränkt detektieren, da die Beobachtungszeit eines Bereiches während der Vorbeifahrt oft nur wenige Sekunden lang ist. Das Fahrzeug kann also lediglich detektieren, dass ein bestimmter Fahrbahnbereich für eine bestimmte kurze Zeit blockiert wurde. Aus mehreren solchen Detektionen könnte in einer zentralen Instanz eine qualitativ höhere Hindernisdetektion generiert werden.

2.3.1.4 Smartphone-Anwendung

Im Bereich der Umfeldwahrnehmung wurde von Fraunhofer FOKUS eine Lösung mit einem herkömmlichen Android-Smartphone weiterentwickelt. Dabei handelt es sich um eine Lösung, deren geringere Präzision bei der Detektion von Objekten im Umfeld durch eine Vielzahl von Messungen ausgeglichen wird.

Im Gegensatz zu den Sensormodellen der SAFARI-Versuchsträger, die die Objektpositionen schon im Fahrzeug relativ zu ihrer durch Selbstlokalisierung gewonnenen sehr genauen Ego-Position bestimmen, werden bei der Smartphone-Lösung die Objektpositionen erst auf dem Backend als Aggregation mehrerer, noch mit Fehler behafteter Positionen bestimmt. Dabei handelt es sich dann um absolute Objektpositionen, die keinen Bezug mehr zur Position des Smartphones haben.

2.3.2 AP 3.2 Selbstlokalisierung

2.3.2.1 Kamerabasierte Selbstlokalisierung

Das Lokalisierungsmodul verwendet die Informationen aus der kamerabasierten Objekt-, Freiraum und Spurerkennung und gleicht sie mit einer externen Karte ab. Aus dem Abgleich wird die Pose des Fahrzeugs relativ zur Karte bestimmt. Das generelle Verfahren wird in Abbildung übersichtsweise dargestellt. Es beruht auf einem MHKF, einem Multihypothesen-Kalmanfilter¹². Dies bedeutet, dass es mehrere konkurrierende Hypothesen für die Pose des Fahrzeugs gibt, die parallel verarbeitet werden. Zu jeder Detektion der Kamera gibt es potenziell mehrere Objekte aus der Karte, zu der diese korrespondieren kann. Für jede dieser möglichen Zuordnungen (und der Möglichkeit, dass keine der Zuordnungen korrekt ist - beispielsweise bei veralteten Kartenabschnitten) wird eine neue Hypothese erzeugt und bewertet. Um ein unkontrolliertes Anwachsen der Zahl der Hypothesen zu verhindern werden ähnliche Hypothesen fusioniert und schwach bewertete eliminiert. Dies wird für jedes Einzelbild durchgeführt und anschließend eine Prädiktion ins nächste Bild berechnet, die dort die a priori Information liefert.

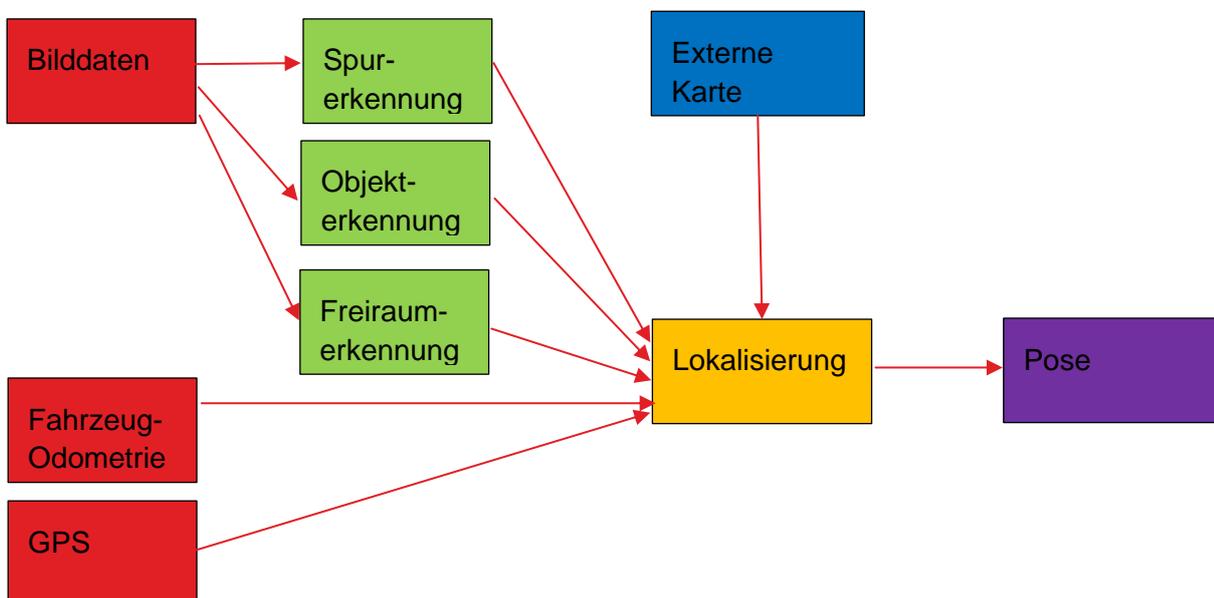


Abbildung 2-11: Kamerabasierte Lokalisierung, generelles Verfahren: Aus den Daten der Kamera werden Objekte wie Freiräume, semantische Objekte (z.B. Verkehrsschilder) oder Spurmarkierungen extrahiert. Diese werden dann unter Verwendung der Fahrzeugodometrie sowie eines GPS-Sensors mit einer externen Karte abgeglichen und daraus die Position und Lage des Fahrzeugs bestimmt.

¹² D. Alspach and H. Sorenson. Nonlinear bayesian estimation using gaussian sum approximations. IEEE Transactions on Automatic Control, 17(4):439{448, 1972

Im Rahmen des Projektes wird von der Senatsverwaltung Berlin zur Verfügung gestelltes Kartenmaterial verwendet¹³. Dieses umfasst eine Vielzahl von hochgenau vermessenen Landmarken wie Spurmarkierungen, Verkehrsschildern oder Verkehrsampeln, ebenso wie Fahrbahnen, Bürgersteige und Radwege (vgl. Abbildung 2-12). Das Kartenmaterial ist sehr genau und sehr detailliert hat aber einige Eigenschaften, die eine Lokalisierung erschweren und die in der Algorithmik berücksichtigt werden müssen. So sind die Karten rein zweidimensional und enthalten keine Höheninformationen, was insbesondere für über die Bodenebene erhabene Objekte wie Verkehrsschilder ein Problem ist. Weiterhin gibt es einige Stellen, an denen die Karte falsch oder nicht aktuell ist. Solche Abweichungen des Kartenmaterials von der Realität zu detektieren und zu melden ist eines der Hauptziele des Projektes. Dennoch stellt dies natürlich eine besondere Herausforderung für die Lokalisierungsalgorithmik dar.



Abbildung 2-12: Senatskarte des Versuchsgebietes. Links: Gesamtansicht, Rechts: Detailansicht (die unbekanntenen Höhen der Schildobjekte wurden dabei durch nominelle Höhen ersetzt)

In Abbildung ist ein Beispiel für die von den Perzeptionsmodulen erkannten Objekte dargestellt, die zum Abgleich mit der Karte verwendet werden. Die Projektion von Kartenelementen in das Kamerabild, der Abgleich mit den dort detektierten Objekten und die daraus berechnete Verfeinerung der Posenschätzung stellt den Kern der Lokalisierungsalgorithmik dar.

¹³ Berlinweite Straßenbefahrungsdaten; 2015; Senatsverwaltung Umwelt, Verkehr und Klimaschutz Berlin, Abteilung Verkehr

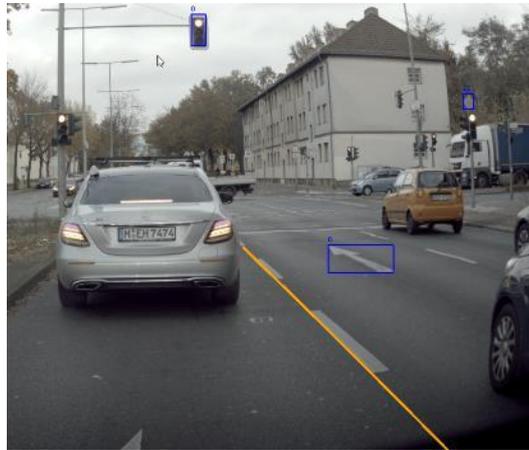


Abbildung 2-13: Aus dem Einzelbild extrahierte Objekte: Spurmarkierungen (orange) und Detektionen aus dem Deep Learning (blau) wie Bodenmarkierungen, Schilder und Ampeln

Zur Bewertung der Lokalisierung wurden drei gemeinsame Datenakquisen im Testfeld durchgeführt. Dabei sind die Fahrzeuge der Projektpartner im Konvoi die gleiche Trajektorie abgefahren. Leider stand für diese Szenen keine Referenzsensorik zur Verfügung, weshalb die Auswertung nur qualitativ erfolgen konnte. Zur Bewertung, ob das Fahrzeug korrekt lokalisiert war wurden dabei zwei Kriterien herangezogen:

- Die Rückprojektion der Karte ins Bild und die 3D Position des Fahrzeugs in der Karte mussten für den menschlichen Auswerter plausibel aussehen (vgl. Abbildung).
- Die Trajektorie musste, mit der von den anderen Projektpartnern gefahrenen Trajektorie zumindest spurgenaue übereinstimmen, andernfalls war einer der Datensätze falsch. Durch Betrachtung der Videos konnte ermittelt werden welcher. Konkret wurden die Daten der HELLA Aglaia mit denen des DCAITI verglichen.



Abbildung 2-14: Links: inkorrekte Lokalisierung, Rechts: korrekte Lokalisierung. Anhand der rückprojizierten Kartenelemente (Fahrbahnmarkierungen, Ampeln und Schilder) kann ein menschlicher Auswerter beurteilen, ob diese korrekt über den im Bild sichtbaren Elementen liegen.

In *Abbildung 2-15* ist eine Auswertung von einer Teilfahrt der koordinierten Datenakquise exemplarisch dargestellt. Dabei wird die kamerabasierte Lokalisierung (blau) mit einer

Lokalisierung, die ausschließlich auf GPS und Fahrzeugodometrie beruht (grün), verglichen, um zu demonstrieren, dass die GPS Navigation durch Einbeziehung der Landmarken verbessert wird.

Bei den koordinierten Datenakquisen zeigte sich insgesamt eine gute Performance des Lokalisierungssystems. Die Lokalisierung war bis auf wenige, sehr kurze Abschnitte stets mindestens spurgenau und insbesondere deutlich präziser als eine reine GPS/Fahrzeugodometrie Lokalisierung.

Unsicherheiten traten, wenn überhaupt, an Kreuzungen auf. Dies lag meist an der hohen Komplexität von Kreuzungen mit vielen Fahrbahnmarkierungen, Schildern und Ampeln, die eine eindeutige Zuordnung schwierig machten.

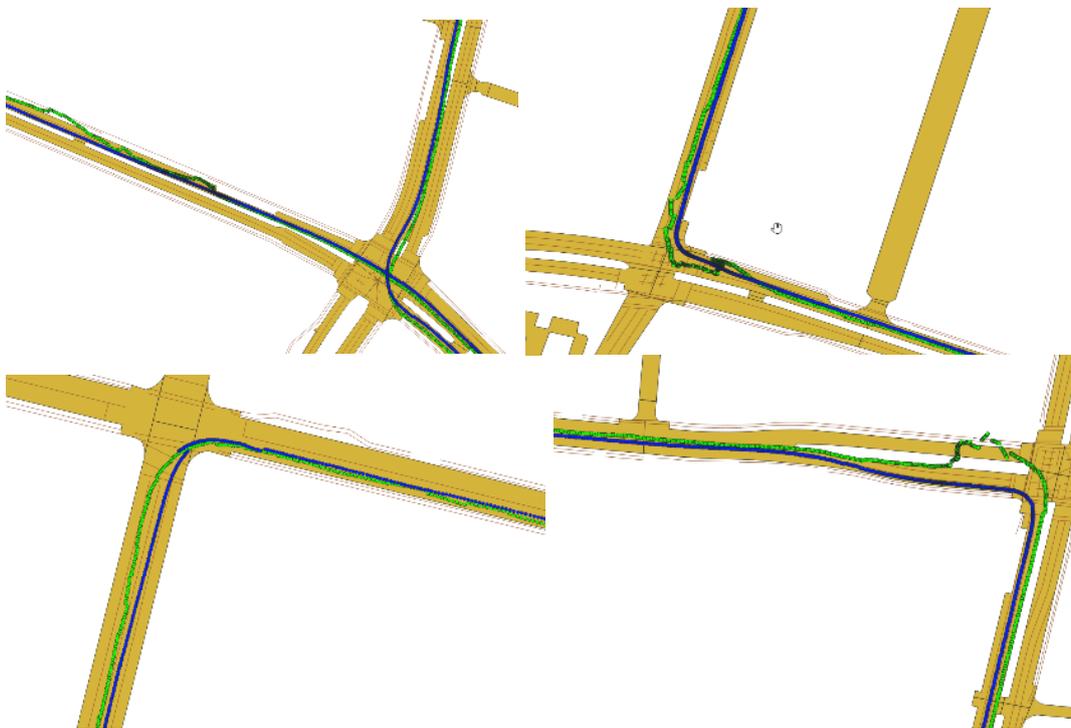


Abbildung 2-15: Fahrt 1 vom 28.2.2019 blau: HELLA Aglaia Lokalisierung, grün: GPS/Fahrzeugodometrie Fusion, links oben: Kreuzung Scharnweberstraße/Ollenhauerstraße, rechts oben: Kreuzung Scharnweberstraße/Eichborndamm, links unten: Kreuzung Eichborndamm/Waldstraße, rechts unten: Kreuzung Waldstraße/Ollenhauerstraße.

Neben den koordinierten Datenakquisen hat die HELLA Aglaia noch zusätzliche Testfahrten mit einem Referenzsystem unternommen. Dieses ermöglichte es eine objektive Ground-Truth zu gewinnen und damit eine quantitative Performance-Analyse durchzuführen. Dieses System wurde auch dazu verwendet das Verfahren unter unterschiedlichen Beleuchtungsbedingungen (Tag/Nacht) zu bewerten. Hierbei zeigte sich ein vergleichbarer, sehr geringer mittlerer Fehler in

Fahrtrichtung (1.14m bei Tag, 0.97m bei Nacht) und senkrecht zur Fahrtrichtung (0.17m bei Tag, 0.22m bei Nacht), aber eine geringere Verfügbarkeit des Systems bei Nacht (93% Verfügbarkeit bei Tag, 86% bei Nacht).

Schließlich wurden auch unterschiedliche Wetterbedingungen untersucht, allerdings ohne Referenzsensorik. Qualitativ zeigten sich sichtbare Performanceeinbußen bei regennasser Fahrbahn, da die Fahrspurextraktion unter diesen Bedingungen weniger zuverlässig war. Dennoch konnte das System meist eine zumindest spurgenaue Lokalisierung gewährleisten.

2.3.2.2 3D-Visions basierte Selbstlokalisierung

Zur Lokalisierung wird ein außerhalb des Projektes entwickeltes Verfahren eingesetzt, das unter Verwendung eines probabilistischen Filters bekannte Landmarken einer Karte des Gebietes mit den 3D-Punktwolken des LiDARs korreliert.

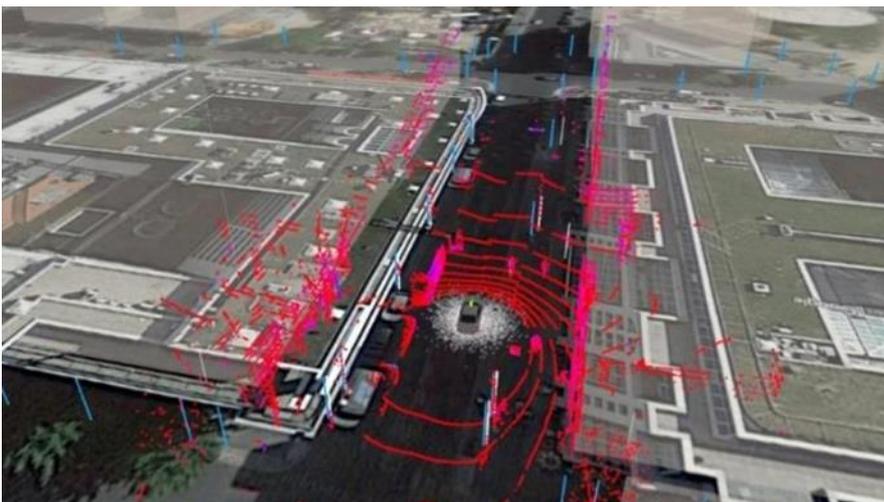


Abbildung 2-16: Beispiel für Lokalisierung der DCAITI-VT: blau – Landmarken in der Karte, weiß detektierte Landmarken, rot - LiDARpunktwolken

2.3.2.3 LiDAR- basierte Selbstlokalisierung

Im Rahmen von SAFARI wurde eine Selbstlokalisierung entwickelt, die die getrackten Masten, Wände und Hausecken verwendet. Da auch nach dem Tracking noch False-positive Landmarken vorhanden sein können, muss der Lokisierungsalgorithmus entsprechend robust gegen fälschlich als vorhanden erkannte Landmarken sein. Der entwickelte Algorithmus verwendet ein Fingerprint-Matching, das auch die Nachbarschaftsbeziehungen der Landmarken zueinander betrachtet. Dadurch ist der Algorithmus sehr robust gegen falsch erkannte Landmarken.

Üblicherweise werden verschiedene Sensoren fusioniert, um eine möglichst genaue Lokalisierung zu realisieren. Zum Beispiel werden sehr oft hochwertige GPS-, IMU- und Odometerdaten fusioniert. GPS erlauben globale Positionsmessungen, sie sind aber nicht immer ausreichend genau, wenn sie in urbanen Umgebungen in Fahrzeugen bei normal üblichen Geschwindigkeiten verwendet werden. Auch hochgenaue GPS-Systeme können Positionsfehler von mehreren Metern aufweisen. Kleine Fehler in den Messwerten von IMUs und Odometer akkumulieren sich und resultieren in einer nicht vollständig vorhersagbaren Drift, so dass eine Lokalisierungsschätzung basierend ausschließlich auf IMU und Odometer Messdaten sehr schnell ungenau wird.

Das entwickelte Selbstlokalisierungsverfahren ist in der Lage, durch Verwendung des Fingerprint-Matching zusammen mit der Fahrzeugodometrie wiederholt eine genauere Position in Echtzeit anzugeben als das hochgenaue GNSS-System von Applanix, das im VT des DCMLR/FU verbaut ist. Lediglich am Anfang ist eine grobe Positionsangabe aus einem GPS notwendig, um die Berechnung der Startposition in Echtzeit zu ermöglichen.

Nur ein Teil der vom VISS und dem FIS-Broker verfügbaren Kartendaten kann zurzeit genutzt werden, um sich damit selbst zu lokalisieren. Dies ist zum Teil der Verwendung eines LiDAR geschuldet. Objekte, wie zum Beispiel Verkehrszeichen und Ampelsignalkörper können mit LiDAR Sensoren nur schlecht erfasst werden. Kameras eignen sich hierfür besser. Daher wurden zum Ende des Projektes die vom HELLA Aglaia-Kamera-System gelieferten Objekte, wie Fahrspurmarkierungen mit in die Lokalisierung einbezogen.

2.3.3 AP 3.3 Anpassung der Sensorik an Versuchsfahrzeuge

2.3.3.1 Der Versuchsträger der HELLA Aglaia

Für die Datenakquise und die Demos wurde ein VW-Touran als Versuchsfahrzeug ausgerüstet (Abbildung 2-17).



Abbildung 2-17: Fahrzeug HELLA Aglaia

Neben einer Mono Fronkamera (100° horizontales Sehfeld, 50° vertikales Sehfeld, 2 Megapixel) wurden noch ein GPS-Empfänger, ein Fahrzeugrechner und eine Kommunikationseinheit integriert (vgl. Abbildung 2-18 und Abbildung 2-19). Über einen CAN-Bus konnten außerdem die Daten der serienseitigen Sensorik abgegriffen werden. So bestand zum Beispiel Zugriff auf die Reifenodometrie. Das Augenmerk lag darauf, eine möglichst seriennahe Sensorkonfiguration zu verwenden.

Mit diesem Fahrzeug war es möglich sowohl Daten für eine Offline-Prozessierung aufzuzeichnen als auch die Algorithmik live und in Echtzeit laufen zu lassen und die Ergebnisse über das Kommunikationsmodul an das Backend zu übertragen.

Es wurde sehr viel Wert auf eine sorgfältige geometrische Kalibrierung der Kamera und eine zeitliche Synchronisation der Sensorsignale gelegt.



Abbildung 2-18: Systemkomponenten HELLA Aglaia

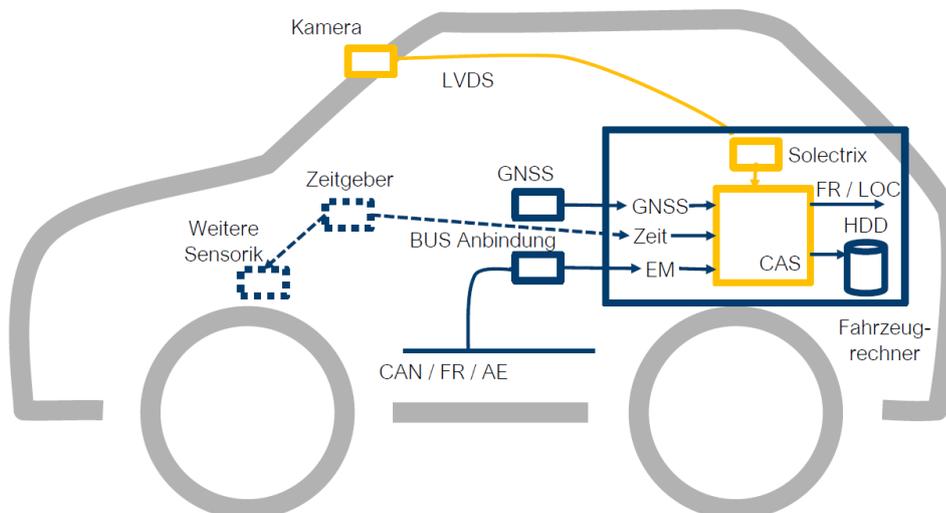


Abbildung 2-19: Gesamtarchitektur Fahrzeug, HELLA Aglaia

Neben dem Fahrzeug der HELLA Aglaia wurden noch die Fahrzeuge des DCMLR/FU und der Senatsverwaltung Berlin mit der HELLA Aglaia eigenen Kamera ausgestattet.

Für das Fahrzeug der Senatsverwaltung Berlin wurde aufgrund der speziellen Geometrie ein spezieller Kamerahalter entwickelt, der den Ansprüchen dieses Transporter-ähnlichen Fahrzeuges gerecht wurde. Weiterhin wurde eine Softwarekonfiguration erstellt, welche die automatische Akquise von Daten mit Versuchsfeld ermöglichte. Eine Verarbeitung der Daten fand in diesem Fahrzeug nicht statt.

Für das Fahrzeug des DCMLR/FU wurde eine Softwarekonfiguration erstellt, die sowohl die Datenakquise als auch die Live Verarbeitung der Daten unterstützt. Die auf Basis der Kamera gewonnenen Informationen wurden durch eine zwischen allen Partnern abgestimmten Protobuf-Schnittstelle (AVF6 Schnittstelle) zum Fusionsrechner übertragen.

2.3.3.2 Versuchsaufbau 3D-Visions

Das 3D-Vision System stellt eine Kombination aus mehreren visuellen Kameras und mehreren LiDARen dar, die auf einem Rig festmontiert sind. Die Sensordaten werden durch ein Framework von Deep Learning Netzen verarbeitet und realisieren in ihrem Zusammenspiel die Freiraumerkennung, Objektdetektion und Klassifikation von Verkehrsobjekten, Verkehrszeichen und Baustellen.

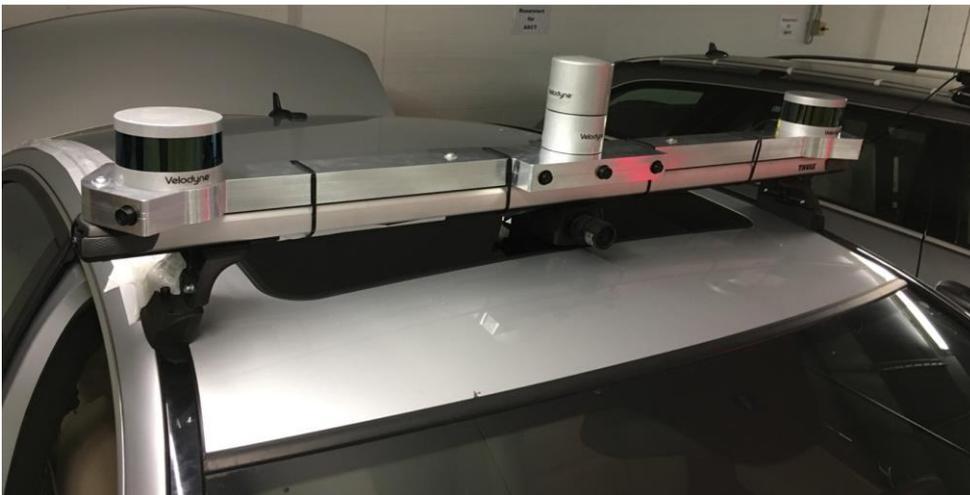


Abbildung 2-20: Zweite Version des 3D-Vision Rigs.

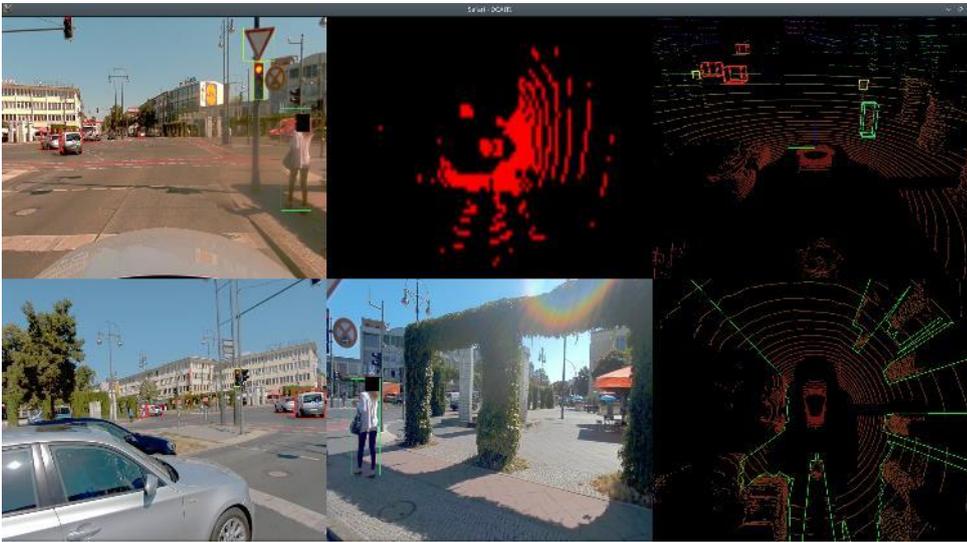


Abbildung 2-21: Resultierende Einzeldaten und Gesamtsicht mit Rig Version 2 (Front/Seiten-Kameras+LiDAR, Beispiel einer Datenakquise im Testgebiet und Freiraum- und Objekterkennung)

2.3.3.3 Versuchsträger des DCMLR/FU

Als Grundlage für die Selbstlokalisierung wurden verschiedene Module zur Erkennung von statischen Objekten aus LiDAR Daten implementiert. Ein Modul trennt Bodenpunkte von Objektpunkten, um die Landmarkenextraktion zu beschleunigen. Die entwickelten Detektionsmodule erkennen in Echtzeit Pfosten-artige Objekte, Wände und Hausecken sowie Fahrbahnmarkierungen aus den Messdaten des Velodyne HDL64E-S2 Rotationslaserscanners. Die Module sind so parametrisiert, dass sie eher Falsch-Positiv Ergebnisse liefern, als dass sie mögliche Erkennungen verwerfen. Falsch-Positiv Detektionen werden anschließend durch ein Tracking-Modul ausgefiltert. Bewegte Objekte werden dabei ebenso ausgefiltert.

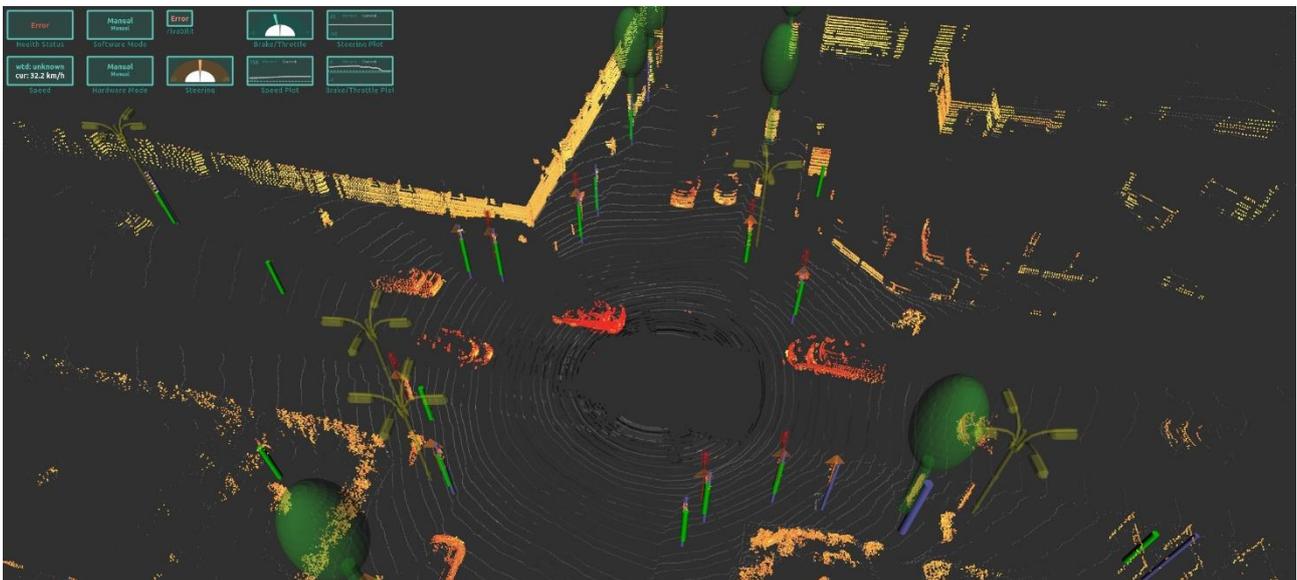


Abbildung 2-22: Detektierte, getrackte und erkannte Objekte des VT der DCMLR/FU
 Blau: detektiert, grün: getrackt, Objekte in der Karte: Bäume, Lampen, VKZ, Ampelpfosten,
 gelb-orange: Objektpunkte, grau-schwarz: Bodenpunkte

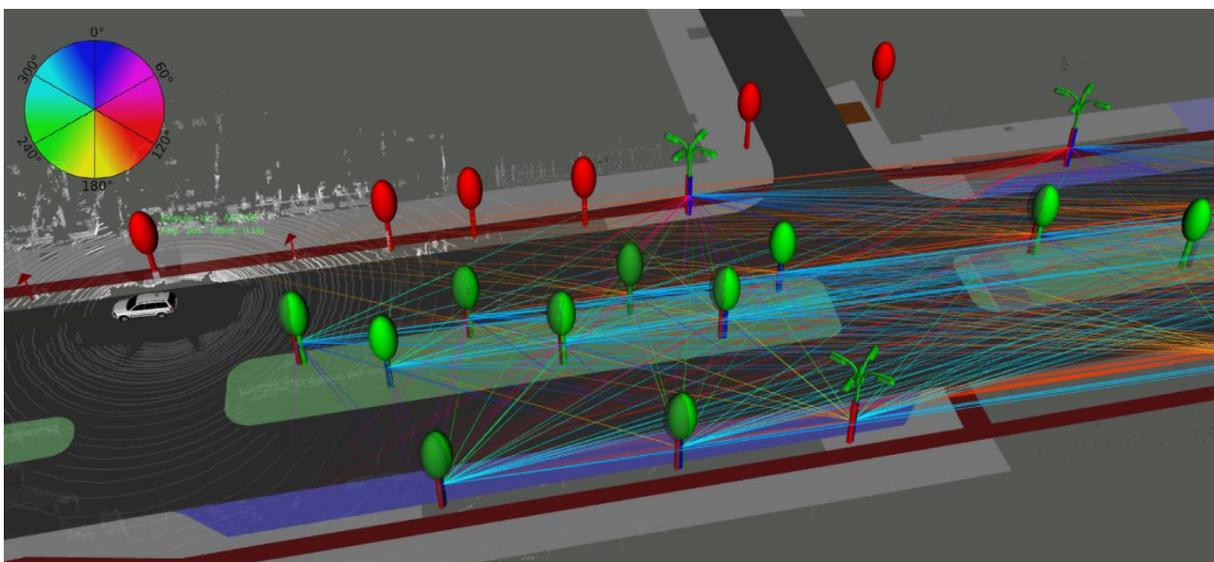


Abbildung 2-23: detektierte und getrackte Objekte mit dem Fingerprint Lokalisierungsverfahren
 Farbe der Linien kodiert den Winkel im UTM Frame
 blaue Zylinder: Karte, rote Zylinder: detektierte und getrackte Objekte

2.3.3.4 Aufbau Smartphone-App

Da es sich bei der um eine Flottenlösung handelt, wurden insgesamt drei Feldtests mit Bussen der BVG bzw. BT durchgeführt. Dazu wurden handelsübliche Android-Smartphones eingesetzt, die mit einer speziell entwickelten Halterung an der Frontscheibe eines Busses angebracht werden. Im Projektverlauf wurden Anpassungen an der Hard- und Software vorgenommen, um die Datenaufnahme und die Datenübertragung zu optimieren.

Einen Vergleich der Ergebnisse der Smartphone-Lösung mit denen der Versuchsträger konnte aus zwei Gründen nicht durchgeführt werden. Einerseits konnte das in SAFARI für die Übertragung von Sensordaten von den Versuchsträgern definierte Format AVF6 hier nicht angewandt werden, da in der jetzigen Version der Smartphone Lösung zusätzliche Inhalte wie Schnipselbilder übertragen werden müssen. Außerdem werden Positionsdaten der Objekte erst auf dem Backend aggregiert; eine absolute Ego-Position ist nicht verfügbar. Andererseits liegt auch eine örtliche Diskrepanz zwischen den Befahrungsdaten vor. Während die Versuchsträger auf dem definierten Testfeld Reinickendorf Daten erfasst haben, wurden die Befahrungsdaten der Smartphone Lösung auf verschiedenen Buslinien erfasst, die oftmals nicht durch das Testgebiet führten.

2.4 AP 4 Kommunikationsmanagement und Backend

Das Kommunikationsmanagement nimmt in SAFARI eine zentrale Rolle ein. Es bezieht sich auf die Kommunikation der SAFARI-Versuchsträger, der V2X-fähigen Infrastruktur und des Backend. Das bedeutet zum einen, dass dieses Arbeitspaket sehr eng mit nahezu allen Arbeitspaketen in SAFARI verknüpft ist, zum anderen aber auch, dass es die viele entscheidende Schnittstellen zu Beteiligten außerhalb des Konsortiums aufweist, die für die Infrastruktur verantwortlich sind.

Durch die Partner wurden Versuchsträger individuell aufgebaut, jeweils mit unterschiedlicher Rechentechnik, unterschiedliche Betriebssysteme sowie eine Vielzahl von unterschiedlichen Sensoren, um das Umfeld wahrzunehmen. Es stellte eine sehr große Herausforderung dar, aus den individuellen Ansätzen und für unterschiedliche technische Konstellationen einheitliche Schnittstellen zu schaffen.

2.4.1 AP 4.1 Kommunikationsmanagement und Vorverarbeitung

Auf Basis der ausgewählten Szenarien wurden in diesem Unterarbeitspaket die folgenden Aspekte untersucht und bewertet:

1. Wo werden Daten erfasst, verarbeitet, weitergeleitet und/oder gespeichert?
2. Welche Kommunikationswege herrschen zwischen Fahrzeugen, der Infrastruktur und dem SAFARI Backend?

3. Welcher Kommunikationsweg ist für welche Aufgabe besser geeignet? Mobilfunk in den Generationen 4G – 5G oder ITS G5?

In den ersten Workshops wurde erarbeitet, dass eine klare Trennung zwischen Versuchsträgern und Backend erfolgen soll. Somit konzentrierte sich das Kommunikationsmanagement auf die Datenerfassung, Vorverarbeitung und Weiterleitung zum Backend. Weiterhin wurde festgelegt, dass im Backend zunächst eine offline Datenaufbereitung erfolgt, die auf aufgezeichneten Daten basiert. Erst zum Ende des Projektes sollten die von den Versuchsträgern erfassten Umfelddaten direkt im Backend prozessiert werden.

Die Umfelderkennung erfolgte über unterschiedliche Sensoren wie LiDAR, Kamera sowie ITS G5. Da die gegenwärtigen Mobilfunkstandards (2G-4G) das enorm hohe Rohdatenaufkommen nicht transportieren können, musste in den Versuchsträgern eine Vorverarbeitung implementiert werden. Parallel wurde ein Speicher- und Upload-Mechanismus umgesetzt. Die Software-Lösungen wurden gemeinsam von den SAFARI-Projektpartnern entwickelt und in den unterschiedlich aufgebauten Versuchsträgern genutzt.

In Bezug auf die V2X-Kommunikation sollten im Rahmen des AP4 die Verkehrsinfrastruktur, hier Lichtsignalanlagen (LSA) durch die Erweiterung mit Road Site Units (RSU) ertüchtigt werden, SPATEM/MAPEM-Meldungen per WLAN 80211p oder C-V2X (LTE-V2X – PC5) an die VT und über Mobilfunk (LTE) mit Unterstützung der SC an den GLOSA-Server auszusenden.

Diese Mobilfunktechnologien sind wie folgt charakterisiert:

- WLAN 802.11P (ITS G5) → 5,895 -5,905 GHz (mit VLB abgestimmt)
- LTE C-V2X /Rel. 14 (PC5) → 5,875 -5,885 GHz (nutzt selbe Antenne wie WLAN und Frequenz)
- Mobilfunk LTE (Uu) → 2,6 GHz über SC und 1,8GHz über Makro im öffentlichen Netz der DTAG

Ein ausführlicher Vergleich der Übertragungsstandards WLAN-V2X und Cellular-V2X in Verfügbarkeit, Leistungsfähigkeit und Einsatzbereichen wurde vorbereitend für das Projekt SAFARI im „iV2X-Konzept“ durchgeführt, um Handlungsempfehlungen für den städtischen Ausbau abzuleiten bzw. Ergebnisse anderer Studien zu verifizieren. Siehe hierzu das von der SenWiEnBe beauftragte Konzeptpapier „iV2X - Integrierte Betrachtung Fahrzeugkommunikation“ (1) sowie weitere Studien der 5GAA - 5G Automotive Association. (2)

Es wurden insgesamt drei Kommunikationswege zur Übertragung der SPAT/MAP Meldung diskutiert und geprüft:

- Weg 1 von der LSA/ RSU direkt an Versuchsträger

- Weg 2 von der LSA/RSU über Mobilfunk LTE zu einem Backend, welches einen App-basierten GLOSA-Service für alle Verkehrsteilnehmer anbietet.
- Weg 3 Indirekte Übertragungsweg von der LSA/RSU über LSA-Infrastruktur Backend (Verkehrsrechner) zum einem Backend, welches einen App-basierten GLOSA-Services für alle Verkehrsteilnehmer anbietet

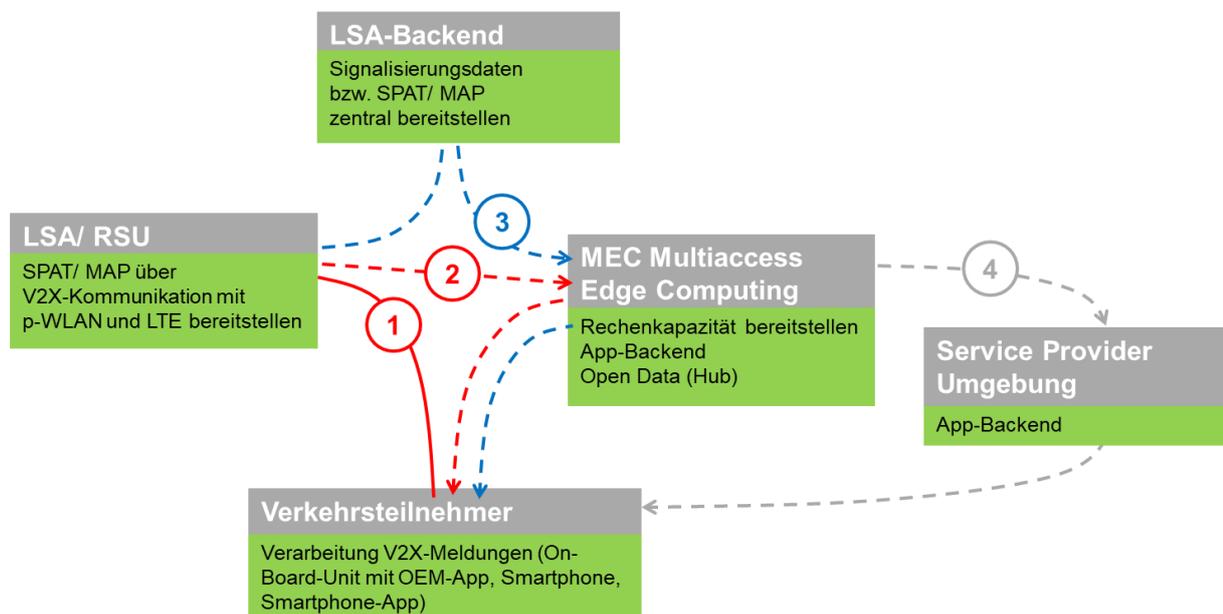


Abbildung 2-24: Darstellung der untersuchten alternativen Kommunikationswege

Weg 1 Technologie p-WLAN: wurde umgesetzt.

Weg 1 Technologie LTE C-V2X: wurde nicht umgesetzt, da noch keine marktreifen Module zur Verfügung standen.

Weg 2 Technologie LTE: wurde nicht umgesetzt, da trotz Vorlage der Sicherheitskonzepte der LSA-Hersteller und der Telekommunikationsanbieters Bedenken der Genehmigungsbehörde hinsichtlich der IT-Sicherheit nicht beseitigt werden konnten.

Weg 3 Technologie Kabelgebundene IT-Vernetzung: wurde nicht umgesetzt, da der derzeit eingesetzte OCIT-Kommunikationsstandard zwischen LSA und LSA-Steuerrechnern nicht echtzeitfähig ist.

Für die funktechnischen Wege wurden im Rahmen der Erarbeitung der Sicherheitsarchitektur die geltenden Normen in der jeweils von den Partnern umzusetzenden Version ermittelt und abgestimmt. Sie sind im Bericht für AP 4.3 in Abschnitt 3.4.1 niedergelegt.

Ein möglicher Service, der in SAFARI getestet werden soll, ist der GLOSA-Service der Deutschen Telekom. Die übertragenen Restlaufzeiten des Ampelstatus (rot, grün) können damit an alle Verkehrsteilnehmer in der Umgebung mit mobilen Endgeräten über die GLOSA-App oder die Fahrzeug-Konsole kommuniziert werden.¹⁴ Basis hierfür ist die Übertragung per Mobilfunk über die Telekommunikationsinfrastruktur.

Zur Weiterentwicklung der Smartphone-Anwendung wurden verschiedene Ansätze zur Reduktion der benötigten Bandbreite bei der Kommunikation mit dem Backend untersucht. Dabei wurden die Rechenleistung der Smartphones in Relation zur verfügbaren Bandbreite betrachtet und mögliche Strategien (Reduktion des Datenvolumens durch Vorverarbeitung, Anpassung der Übertragungsraten) spezifiziert.

2.4.2 AP 4.2 Austauschformate

Die Idee, einheitliche Austauschformate zu definieren entstand, nachdem in AP 4.1 die diversen Ausstattungen der Versuchsträger mit den Herausforderungen, über verschiedene Betriebssysteme und unterschiedliche Software-Frameworks hinaus kommunizieren zu müssen.

Es wurden unterschiedlichen Software-Instanzen für die Datenerfassung, -verarbeitung, -speicherung und -weiterleitung entwickelt. Damit diese Module über die beschriebenen Grenzen hinaus kommunizieren können, müssen betriebssystemübergreifend Nachrichtenaustauschbibliotheken und definierte Datenaustauschformate verwendet werden.

Als Nachrichtenaustauschbibliotheken wurden MQTT und ZeroMQ untersucht. Alle Projektpartner hatten bereits Erfahrungen mit Message Queue Systemen. Die Entscheidung fiel zugunsten von zeroMQ da es als Open Source Tool von einer breiteren Community entwickelt und gepflegt wird als MQTT. Darüber hinaus benötigt es keine zentrale Instanz zur Steuerung der Kommunikation. Weiterhin bietet es eine Abstraktion von asynchronen Nachrichtenwarteschlangen, unterstützt mehrere Nachrichtenmuster und Nachrichtenfilterung (Abonnements) sowie den nahtlosen Zugriff auf mehrere Transportprotokolle.

Als Austauschformat für die zu übertragenden Daten zwischen den Software-Modulen musste eine Entscheidung zwischen JSON und Protobuf getroffen werden. Für SAFARI stellt Protobuf die

¹⁴ Siehe separates Dokument „GLOSA-Service“

optimale Lösung dar. Performanceanalysen weisen nach, das Protobuf mindestens genauso schnell wie, häufig sogar deutlich schneller als JSON verarbeitet werden kann.

Darüber hinaus ist der Nachrichtenaustausch mittels Protobuf kaskadiert in SAFARI aufgebaut. Das bedeutet, dass jeder Versuchsträger einen Basissatz an Informationen bereitstellen muss und diesen um Inhalte seiner Sensorik erweitern kann. Im Ergebnis werden individuelle Ergebniswerte von jedem Versuchsträger erfasst und verarbeitet.

2.4.3 AP 4.3 Sicherheitsarchitektur

Wie in allen Kommunikationssystemen benötigt auch das SAFARI-Kommunikationssystem eine Sicherheitsarchitektur. Ziel dieses Unterarbeitspaketes war es, eine Bedarfsanalyse an die Sicherheitsschutzziele Vertraulichkeit, Integrität, Verfügbarkeit und Authentizität für das SAFARI-System durchzuführen. Basierend auf der Bedarfsanalyse wurden geeignete technische Schutzmaßnahmen ausgewählt, die in den zu erwartenden Bedrohungslagen angemessen sind.

Die Bedarfsanalyse umfasst das gesamte SAFARI-Kommunikationssystem. Dies umfasst die Verkehrsteilnehmer und Fahrzeuge, die ITS G5 und Mobilfunkkommunikation sowie die Backendsysteme von SAFARI und vom Verkehrssenat. Darüber hinaus wurden in der Bedarfsanalyse die Sicherheitsanforderungen und der Datenschutz beschrieben. Besonderes Interesse gilt dem Thema Datenschutz-Grundverordnung (DSGVO) und der potenziellen Erfassung von personenbezogenen Daten. Das Ergebnis sagt aus, dass DSGVO-relevante Daten potenziell an folgenden Instanzen erfasst und verarbeitet werden können:

- Durch die Sensoren der Versuchsträger
- Fahrer der Versuchsträger die einen Messkampagne fahren
- Bei Demonstrationen der Projektergebnisse

Die entsprechenden Datenschutz-Maßnahmen sind ebenfalls erfasst und ausführlich im Dokument AP 4.3 Sicherheitsarchitektur beschrieben.

Letztendlich wurden technische Schutzmaßnahmen im SAFARI-Umfeld beschlossen und umgesetzt. Auch diese sind ausführlich im Dokument AP 4.3 Sicherheitsarchitektur beschrieben.

2.4.4 AP 4.4 Hardware/ Software-Umsetzung

Auf der Basis der gemeinsam entwickelten Konzeption des Kommunikationsmanagements (siehe Abschnitt 2.4.1) wurde die hardware- und softwareseitige Kommunikationsarchitektur für die Versuchsträger auf von IAV und den Projektpartnern erfolgreich umgesetzt.

Im Rahmen der Vehicular-2-Infrastructure (V2I) Umsetzung, basierend auf dem aktuellen ITS G5 Standard, klärten die SAFARI Projektleitung, SenUVK und IAV die Installationsvoraussetzungen an den Lichtsignalanlagen (LSA). Die SAFARI Projektleitung, SenWEB und die Deutsche Telekom bereiteten den Aufbau der 4G Small Cells vor.

Ein Teilaspekt des Projektes ist die Verbesserung der Mobilfunkabdeckung mit Mobilfunksendestationen geringer Leistung (Small Cells) an geeigneten Trägerstrukturen im öffentlichen Straßenland, wie mastartigen Konstruktionen für die Beleuchtung, Werbung und Information. Es wurden technische, organisatorische Abläufe und rechtliche Fragestellungen auf Verbesserungspotential hin untersucht, um den bevorstehenden Mobilfunkausbau mit Small-Cells aus städtischer Sicht schnell und gezielt vorantreiben zu können. In SAFARI erfolgte der Mobilfunkausbau mit LTE-Small-Cells. Es wird erwartet, dass sich die Ergebnisse adäquat auf den 5G-Mobilfunkausbau übertragen lassen.

Zu Beginn erfolgte eine Detailplanung für die RSU an den LSA hinsichtlich Ausrüstung und Anbringung sowie eine Angebotslegung für Hersteller. Die Beauftragung für die Umrüstung der LSA/RSU erfolgte durch SenUVK.

Insgesamt wurden 8 bestehende LSA (2x Swarco, 6x Siemens) mit zusätzlichen ITS G5 Road Side Units (RSU) ausgestattet. Nach einer umfangreichen Testphase sind diese nun in der Lage standardkonforme Nachrichten (SPATEM und MAPEM) auszusenden.

Die VT-Partner DCMLR/FU, FOKUS, HELLA Aglaia und die IAV haben an Funktionstests teilgenommen und gemeinsam mit anderen Partner Umfelddaten – nach dem Aufbau der RSU, einschließlich V2X-Meldungen - erfasst und an das SAFARI-Backend gesendet, wo diese im Rahmen der selbstaktualisierenden Karten verarbeitet wurden.

2.5 AP 5 Selbstaktualisierende Karte

Hochgenaue Karten sind eine Voraussetzung für autonomes Fahren. Im SAFARI-Projekt wurde daher untersucht, in wie weit Fahrzeuge, die mit verschiedener Sensorik ausgestattet sind, dazu beitragen können, diese Karten aktuell zu halten.

Im Arbeitspaket 5 des Projekts wurde mit dem SAFARI-Backend eine zentrale Ebene konzipiert und umgesetzt, in der alle Informationen zusammenlaufen und ausgewertet werden können. Als Ergebnis erhält man Informationen über geänderte Kartenobjekte, die genutzt werden können, um die hochgenaue Referenzkarte zu aktualisieren. Das folgende Bild zeigt eine vereinfachte Darstellung des Backend.

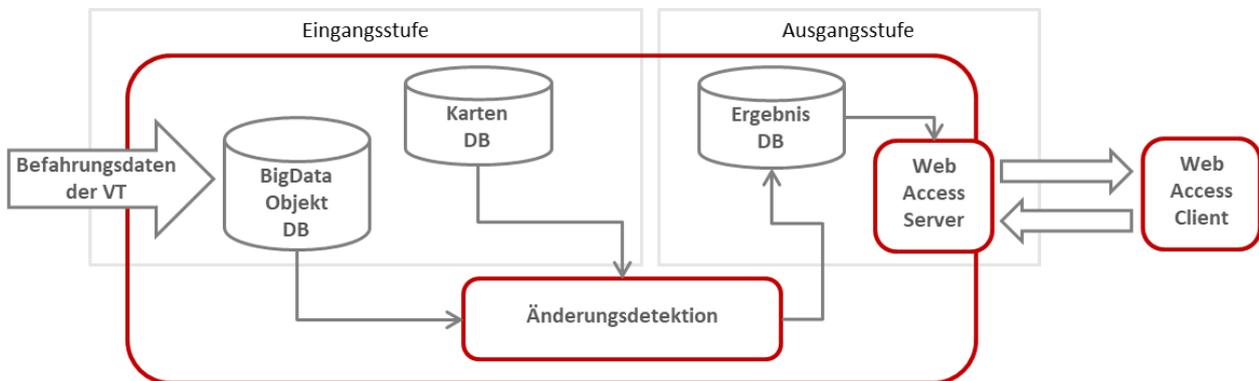


Abbildung 2-25: Darstellung des SAFARI-Backend

Das Backend besteht grundsätzlich aus drei Komponenten, die gleichzeitig den Fluss der Datenverarbeitung aufzeigen:

1. Eingangsstufe: Diese Komponenten sind für den Empfang, die Transformation sowie die Speicherung von SAFARI-relevanten Daten zuständig. Dabei handelt es sich einerseits um die Objektdaten von den verschiedenen Versuchsträgern, andererseits um aktuelle Kartendaten, die in einer PostGIS-Datenbank zur Verfügung gestellt werden.
2. Änderungsdetektion: Die eigentliche Verarbeitung der Daten findet in einer Ausführungsumgebung statt, wo die Algorithmen zur Änderungsdetektion laufen und auf alle benötigten Informationen zugreifen können.
3. Ausgangsstufe: Diese Komponente ist für die Speicherung der detektierten Änderungen in einer Ergebnis-Datenbank und ihrer Darstellung bzw. Konvertierung in verschiedene Ausgangsdatenformate verantwortlich.

2.5.1 AP 5.1 Datenbankadministration

Mit der physischen Inbetriebnahme des SAFARI-Backend bei FOKUS wurde eine zentrale Komponente umgesetzt, die die in AP 2 spezifizierte High Level Backendarchitektur mit den wesentlichen Aspekten der Data Ingestion (Datenlogger), Data Storage für Bulk, Skalar und Kartendaten (GIS-Datenbank), sowie einer gesicherten Ausführungsumgebung, berücksichtigt (siehe auch AP 5.4). Das Backend wurde und wird (bis zwei Jahre nach Projektende) von FOKUS gehostet und FOKUS ist während der gesamten Zeit für Administration und Support verantwortlich. Zur Umsetzung der Sicherheit wurde ein Authentifizierungsmechanismus aufgesetzt, so dass nur autorisierte Nutzer auf das Backend Zugriff haben.

Zur Speicherung der von den Versuchsträgern detektierten Objekte wurde eine Big-Data Datenbank basierend auf Accumulo und Hadoop aufgesetzt. Verschiedene Tools zur intelligenten Indizierung der (key-value) Big-Data-Datenbank sowie zum Monitoring wurden im SAFARI-Kontext angepasst. Zum Zugriff auf die Objektdaten wurde mit dem Big-Data-Connector (BDC) ein Instrument zur Verfügung gestellt, das eine Filterung nach verschiedenen Kriterien ermöglicht.

2.5.2 AP 5.2 Klassifikation

Zur Übertragung, Transformation und Speicherung der Objektdaten von den verschiedenen Versuchsträgern wurde ein gemeinsames Format (AVF6-Protobuf) definiert und eine weiterentwickelte Softwarekomponente zur Datenübertragung für alle Versuchsträger zur Verfügung gestellt (Datenlogger). Durch die programmatische Nutzung der AVF6-Schnittstelle wird eine typsichere Umsetzung gewährleistet und dadurch implizit eine Plausibilitätsprüfung auf den Daten durchgeführt, die schließlich zum Backend hochgeladen werden.

2.5.3 AP 5.3 Referenzerzeugung

Der Aufbau der Kartendatenbank begann mit der Auswahl eines geeigneten Kartenaustauschformates. Dabei wurde das Ausgangsdatenformat der Senatskarte (shape-Files zur Verfügung gestellt über den FIS-Broker (<https://fbinter.stadt-berlin.de/fb/index.jsp>) ebenso berücksichtigt, wie die Zielformate, die in den einzelnen Versuchsträgern Verwendung finden. Nach einer Evaluation verschiedener Formate, fiel die Wahl auf eine SQLite-Datenbank mit einer SpatialLite-Erweiterung.

Für die Referenzkartenerzeugung und Speicherung sowie für Zugriffe auf die Kartendaten wurden verschiedene REST-Schnittstellen implementiert. Über verschiedene Abfragen können die Objekte aus dem Datenbestand über geografische Parameter und/oder nach Objekten (featureList) ausgewählt werden. Auch eine Aktualisierung der Karte nach einer Änderungsdetektion kann über diese Schnittstelle wieder eingespielt werden.

2.5.4 AP 5.4 Veränderungsdetektion

Zur Realisierung des Backend und zur Unterstützung einer gemeinsamen Entwicklung wurde bei Fraunhofer FOKUS eine Ausführungsumgebung bereitgestellt. Damit ist es möglich, dass jeder Partner seine Algorithmen in der Laufzeitumgebung ausführen kann und Zugriff auf die gemeinsame Datenbasis (Objekt- und Kartendatenbanken) hat. Die Laufzeitumgebung (Tomcat)

selbst läuft in einem abgeschotteten Docker-Container mit beschränkten Zugriffsmöglichkeiten nach außen.

Die von der IAV implementierte Backend-Änderungsdetektion, die auf allen Befahrungsdaten (egal von welchen VT eingefahren) gearbeitet hat, ist in zwei Phasen aufgeteilt. In der ersten Phase werden die Befahrungsdaten vorverarbeitet, d.h. die übertragenen Sensordaten werden unter Berücksichtigung verschiedener Anforderungen geclustert. Das passiert in regelmäßigen Abständen (z.Zt. 8h), die über eine REST-Schnittstelle konfiguriert werden kann und so die Daten regelmäßig aktuell hält. In der zweiten Phase der Änderungsdetektion wird der eigentliche Abgleich der detektierten Objektdaten mit den Kartendaten durchgeführt. Dieser Schritt wird durch die manuelle Auswahl einer Exportfunktion gestartet, der optional mehrere Parameter mitgegeben werden können.

Zur Vorbereitung einer Änderungsdetektion mit Hilfe von Smartphone-Daten wurde auch die Smartphone-App weiterentwickelt und die grundsätzliche Machbarkeit dieses Lösungsansatzes konnte gezeigt werden. Allerdings ist die Klassifikation auf dem Smartphone bisher nicht genau genug und auch serverseitig hat sich gezeigt, dass die verwendeten Algorithmen noch nicht die benötigte Präzision in der Verortung der Objekte haben, so dass auch hier eine Weiterentwicklung erforderlich ist und die Daten daher nicht für eine Änderungsdetektion genutzt werden konnten.

Es wurde durch den Versuchsträger der DCMLR/FU auch eine Veränderungsdetektion auf dem Fahrzeug erprobt. Das Ergebnis der Änderungsdetektion sind auch hier wiederum shape-Files für die verschiedenen Kartenobjekte, die die identifizierten, veränderten oder verschwundenen Objekte darstellen. Zusätzlich wird eine Datei mit neuen detektierten Objekten zurückgegeben, die nicht automatisiert einer Kartenobjektklasse zugeordnet werden konnten.

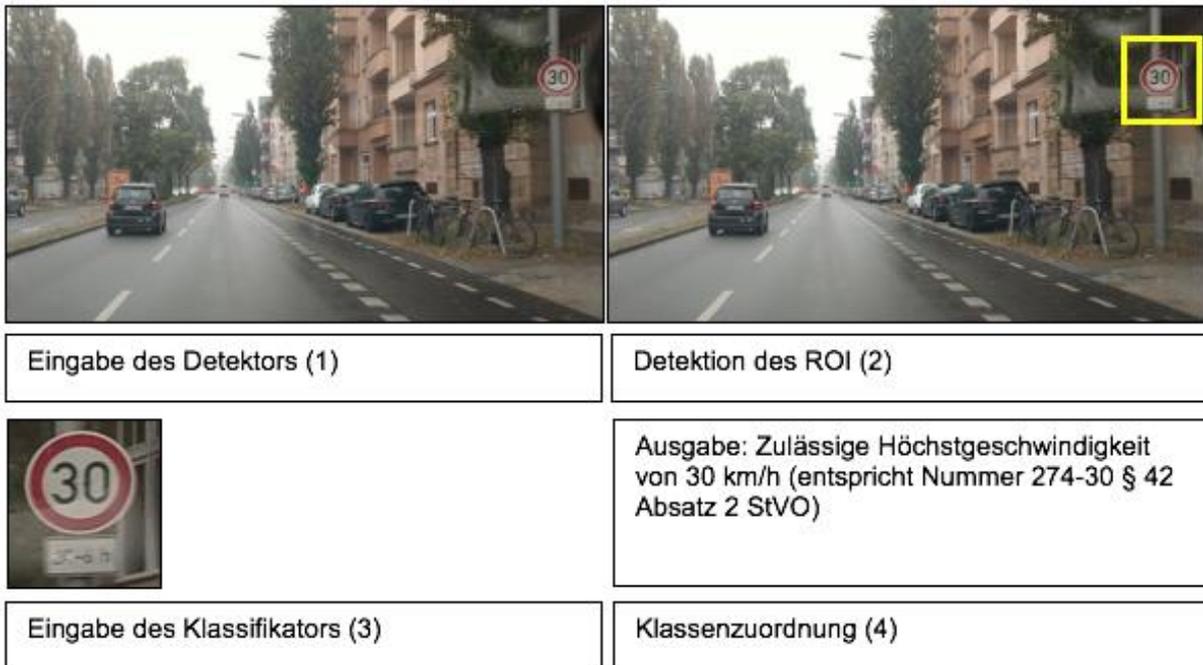


Abbildung 2-26: Erkennung und Klassifikation von Verkehrszeichen (gelbe Boxen) als statische Objekte durch die Anwendung eines weiteren Deep Learning Netzwerks durch 3D Vision (DCAITI).

Actual Label: Double curve



Speed limit (120km/h)
 Children crossing
 Right-of-way at the next intersection
 Speed limit (50km/h)
 Double curve

Actual Label: Keep left



Speed limit (50km/h)
 Ahead only
 Keep left
 Dangerous curve to the left
 Turn right ahead

Actual Label: No entry



Speed limit (80km/h)
 Stop
 No entry
 No passing for vehicles over 3.5 metric tons
 Priority road

Abbildung 2-27: Prognosewahrscheinlichkeiten für erkannte Verkehrszeichen

Während der Selbstlokalisierung werden erkannte Landmarken mit der VISS-Karte abgeglichen, um die eigene Position zu ermitteln. Werden dabei einige Landmarken an einer leicht versetzten Position detektiert und getrackt, kann diese Information direkt genutzt werden, um daraus eine Aktualisierung der Position dieser Landmarken für die VISS-Karte zu generieren. Eine Änderungsdetektion der zur Selbstlokalisierung verwendeten Landmarken wurde in dieser Form auf dem Versuchsfahrzeug des DCMLR/FU implementiert. Um die Genauigkeit der Selbstlokalisierung zu erhöhen, wurde mit einem SLAM-Ansatz die lokale Kopie der VISS-Karte mit den aus der Änderungsdetektion ermittelten Versätzen der Landmarken sukzessive eine aktualisierte lokale Karte erstellt, die dann wieder zur Selbstlokalisierung genutzt wird.

2.5.5 AP 5.5 Verkehrsmanagement

Die Ergebnisdaten wurden zu mehreren Zeitpunkten durch die VISS-Geschäftsstelle bewertet und diese Bewertung im Rahmen der Koordinierungsberatungen an das Konsortium zurückgemeldet. Zusammenfassend lässt sich feststellen, dass geographische Veränderungen von Landmarken und Objekten wie Verkehrszeichen gut erkannt werden können und auch neue Objekte können gut identifiziert werden. Es konnten jedoch noch nicht alle im Zusammenhang mit der Bewertung der SAFARI-Ergebnisse beobachteten Veränderungen eindeutig geklärt werden. Insbesondere stellen die von der Änderungsdetektion gemeldeten verschwundenen Objekte noch eine Herausforderung dar, da wesentlich mehr verschwundene Objekte gemeldet wurden als in Realität wirklich entfernt wurden. Daher erfordert die Änderungsdetektion eine Weiterentwicklung, bei der zur Validierung auch Bilddaten verwendet werden sollen, wie es in einem Nachfolgeprojekt des Konsortiums (SHUTTLES&CO) jetzt vertieft untersucht werden soll.

2.6 AP 6 Systemintegration

2.6.1 AP 6.1 SW-Komponenten zur Selbst- und Objektlokalisierung

Die SW-Komponenten zur Selbst- und Objektlokalisierung wurden in den verschiedenen VT je nach Sensorausstattung implementiert.

Das DCAITI entwickelte einen neuartigen 3D-Vision Sensor, der durch ein KI-basiertes Softwareframework die Objekt- und Freiraumerkennung sowie die Lokalisierung realisiert. Für das 3D-Vision-System wurden mehrere LiDAR-Sensoren und Videokameras sowie eine Umfeldwahrnehmung und Selbstlokalisierung mit besonders hoher Präzision integriert. Die Detektion von sowohl statischen und dynamischen Verkehrsobjekten als auch Verkehrsräumen ermöglichte als grundlegender AVF6 Dateninput des Backend die Änderungsdetektion und

Aktualisierung hoch genauer Karten. Damit wurde die praktische Erprobung des Zusammenspiels zwischen dem vernetzten Fahren und der kooperativen Infrastruktur erfolgreich demonstriert.

Der HELLA Aglaia Versuchsträger wurde mit einer seriennahen Monokamera, einem Mess-PC und weiterer Sensorik wie einem GPS Sensor ausgestattet (für die Details vgl. Abschnitt 2.3.3.1). Die Kamera wurde zusätzlich auch in die Fahrzeuge des DCMLR/FU und der Senatsverwaltung integriert. Die Software bestand aus den folgenden Komponenten: Bild-Vorverarbeitung, inklusive Belichtungssteuerung, Empfang und Synchronisation der Zusatzsignale (CAN/GPS) mit den Bildsignalen, Detektionsalgorithmik (vgl. Abschnitt 2.3.1.1), Lokalisierungsalgorithmik (vgl. Abschnitt 2.3.2.1), Konvertierung in das AVF6 Format und Upload. Diese Komponenten wurden ganz (HELLA Aglaia Fahrzeug) oder teilweise (Fahrzeuge des DCMLR/FU und der Senatsverwaltung) in die Testfahrzeuge integriert, wobei hier, gerade bei der Verarbeitung der Zusatzsignale, erhebliche Anpassungen nötig waren.



Abbildung 2-28: Abbildung der 3 VT von (v.l.n.r.) HELLA Aglaia, DCMLR/FU, DCAITI

Um auch die Landmarken zu nutzen, die sehr gut mit Kameras und weniger gut mit LiDAR-Sensoren erkannt werden können, wurde eine neu entwickelte automotive-grade Kamera von HELLA Aglaia in das Fahrzeug des DCMLR/FU integriert. Das komplette System besteht aus der Kamera, einer Video-Capture-Card von Solectrix, einem Hochleistungs-Laptop und der DV-Software "Cassandra" von HELLA Aglaia. Der Laptop ist mit einer Intel i7 CPU, mit einer NVIDIA 1080 GPU und 32 GB RAM ausgestattet, um die KI-Algorithmen zur Erkennung der Landmarken, wie Verkehrszeichen und Ampelsignalkörpern in Echtzeit ausführen zu können. Die DV-Software

von HELLA Aglaia benötigt Odometrie- und Positionsdaten, um eine Schätzung der 3D Position der erkannten Objekte durchzuführen. Dementsprechend wurden Module in das ROS-Framework des Hauptrechners integriert, die Odometrie- und Positionsdaten per Netzwerk der DV-Software von HELLA Aglaia bereitstellen, und es wurden Module integriert, die die von der DV-Software erkannten Objekte per Netzwerk empfangen und im ROS-Framework des Hauptrechners verfügbar machen.

FOKUS hat sich mit der Verbesserung der serverseitigen Komponenten zur Selbst- und Objektlokalisierung beschäftigt. Zudem mussten für den Einsatz in Bussen verschiedene Systemfunktionen der mobilen Geräte angepasst werden (z.B. Stromversorgung, vereinfachtes Handling für die Busfahrer*innen, schwarzer Bildschirm während der Datenaufzeichnung).

2.6.2 AP 6.2 SW-Komponenten zur Kommunikation

Um die Nachrichten der im Testfeld Reinickendorf verbauten RSU empfangen und auswerten zu können, wurde eine V2X-OBU von Cohda in die VT integriert. Mit Hilfe des SDK von Cohda wurde ein Softwaremodul entwickelt, das V2X Nachrichten, wie SPaT/Map empfängt und sie an den Hauptrechner per Netzwerkschnittstelle übermittelt. Entsprechend wurden Softwaremodule zum Empfang und zur Visualisierung der SPaT/Map Nachrichten in die VT des DCMLR/FU, FOKUS, DCAITI und IAV integriert.

Zur Kommunikation mit dem Backend wurde ein Datenlogger von FOKUS in Absprache mit den Partnern angepasst und in die VT integriert. Dem Datenlogger werden die erkannten und getrackten sowie die verändert detektierten Objekte übergeben, der diese dann z.B. per Mobilfunk an das Backend überträgt. Der Logger kann in den zwei Modi Live-Logging und Offline-Logging betrieben werden. Im Live-Logging Modus werden die Objektdaten während der Fahrt im Testfeld sofort übertragen, während im offline Modus die Objektdaten aus aufgezeichneten Rohdaten generiert, gesammelt und anschließend als ein großes Datenpaket an das Backend übertragen werden.

Die Installation und Inbetriebnahme der Datenerfassungskomponente auf den Versuchsträgern wurde von FOKUS unterstützt und notwendige Anpassungen für verschiedene Zielsysteme implementiert (Windows, Linux).

2.6.3 AP 6.3 SW-Komponenten zur Kartenverwendung

Die zur Selbstlokalisierung notwendige Karte wurde anfangs händisch aus den VISS-Kartendaten extrahiert und in ein eigenes Format übertragen. Im Laufe des Projektes wurde diese Karte in das

Format integriert, das vom Kartenexporttool des Backend bereitgestellt wird. Das Backend exportiert die aktuelle Basiskarte als spatialite-Datenbankdatei, die in erweiterter Form von den Selbstlokalisierungsmodulen auf den VT direkt verwendet werden.

2.6.4 AP 6.4 Tests, Gesamtintegration und Datenaufzeichnung

Die im Rahmen von SAFARI entwickelten Softwaremodule wurden regelmäßig jeweils einzeln und im Zusammenspiel mit den anderen Modulen in einer Simulationsumgebung getestet. Dabei wurde auch auf aufgezeichnete Daten aus dem Testfeld zurückgegriffen. Nach erfolgreichem Test in der Simulation wurden die Module dann im Testfeld Reinickendorf erprobt. Es wurden auch Feldtests auf der Thielallee und Englerallee in der Nähe der Freien Universität durchgeführt, insbesondere die neu entwickelte Selbstlokalisierung und das autonome Fahren mit der neuen Selbstlokalisierung wurden zuerst dort und später im Testfeld Reinickendorf erprobt.

Während der gesamten Projektlaufzeit wurden regelmäßig Datenakquisefahrten im Testfeld Reinickendorf durchgeführt. Insbesondere nach erfolgter Integration neuer Hard- bzw. Softwaremodule wurden die Daten während der Tests aufgezeichnet und anschließend analysiert. Es wurden zusätzlich auch Datenaufzeichnungen während der Demonstrationen durchgeführt.

Zur Datenerfassung mit der Smartphone-Anwendung wurden mit der BVG bzw. BT mehrere Feldversuche geplant und durchgeführt.

2.7 AP 7 Demonstration und Evaluation

2.7.1 AP 7.1 Vorbereitung der Demonstration

Zentrales Anliegen der Forschungsprojekte im Bereich AVF ist es, die erzielten Ergebnisse der geförderten Projekte einer breiteren Fachöffentlichkeit zu präsentieren

Das SAFARI Konsortium hat mehrere Demonstrationen veranstaltet, um die Ergebnisse des Projektes SAFARI nicht nur in Form von Berichten darzustellen, sondern in Echtzeit erleben zu lassen.

SAFARI hatte mit seinem Schwerpunkt eine selbstaktualisierende digitale Karte für automatisiertes und vernetztes Fahren bereitzustellen, einen engen Bezug zum Thema Digitalisierung der Verwaltung insbesondere für die digitalen Karten des Landes Berlin, die nur in abstrakten Daten abgelegt sind. Deshalb wurde für die Demonstrationen von allen Partnern viel Wert auf eine visuelle Umsetzung der Ergebnisse gelegt.

Entsprechend wurden vor ausgewähltem Publikum einerseits die Erkenntnisse in Form von Vorträgen erläutert, andererseits den interessierten Fachpersonen die Gelegenheit gegeben, mit den Versuchsträgern mitzufahren und die umgesetzten Ergebnisse erleben zu können.

Zur Vorbereitung der Demonstrationen wurde frühzeitig zu Projektbeginn ein Demonstrationskonzept aufgesetzt, um die für die möglichen Arten der Demonstration notwendigen Voraussetzungen in die Spezifikation der Ausrüstung der VT bzw. der Backend und den Visualisierungsmöglichkeiten einfließen lassen zu können. Es wurden Drehbücher erstellt, in denen Szenarien und Abläufe räumlich und zeitlich beschrieben wurden.

In der Umsetzung der verschiedenen Demonstrationen wurde auf diese Drehbücher zurückgegriffen.

2.7.2 AP 7.2 Durchführung der Demonstration

Es wurden im Projektverlauf insgesamt drei Demonstrationen durchgeführt:

- Die erste Demonstration fand am 27. März 2019 statt. Zu diesem Zeitpunkt waren die gesetzten Ziele so weit erreicht, dass mit verschiedenen Versuchsträgern Fahrten mit interessiertem Fachpublikum im Testgebiet angeboten werden konnten, um die Ergebnisse erfahrbar zu machen.

Es wurden neben Vorträgen zum Projekt und inhaltlichen Schwerpunkten die verschiedenen Anwendungsszenarien, mit Fahrzeugen der Projektpartner DCMLR/FU Berlin, HELLA Aglaia, Fraunhofer FOKUS und DCAITI auf Fahrten durch die Straßen des Testfeldes demonstriert. Während der Fahrten wurden jeweils die Sensorken und die verwendeten Prozesse detailliert erläutert.

- Die zweite Demonstration fand am 13. Juni 2019 statt, da das Interesse bestand, die erste Demonstration auch innerhalb der Verwaltung zu zeigen und mit weiteren Teilnehmern, die sich mit ähnlichen Projekten beschäftigten, in Austausch zu treten.
- Die Abschlussdemonstration fand am 10. Dezember 2019 statt. Ziel war die öffentlichkeitswirksame Eröffnung der Abschlussveranstaltung des Projekts SAFARI und anschließende vertiefende Vorstellung der Projektergebnisse für eine begrenzte Fachöffentlichkeit sowie für den Fördergeber. SAFARI hatte mit seinem Schwerpunkt eine selbstaktualisierende digitale Karte für automatisiertes und vernetztes Fahren bereitzustellen einen engen Bezug zum Thema Digitalisierung der Verwaltung insbesondere für die digitalen Karten des Landes Berlin.

Als repräsentativer Veranstaltungsort wurde die Humboldt-Bibliothek in Berlin Tegel gewählt. Das in unmittelbarer Nachbarschaft zum Veranstaltungsort erlebbare Projekt See-Meile wurde ebenfalls einer größeren Fachöffentlichkeit vorgestellt. Hier wurde erstmals ein autonom fahrender Kleinbus im Linienverkehr im öffentlichen Straßenraum betrieben.

Die einzelnen Forschungsschwerpunkte wurden dem Fachpublikum jeweils in Form von Vorträgen, an den Informationsständen der Projektpartner und durch Live-Vorführungen in den Forschungsfahrzeugen demonstriert:

- Autonomes Fahren (Abschlussdemonstration)
- Perzeption automatisierter Fahrzeuge mit verschiedenen Sensoriken
- V2X-Anwendung GLOSA und Auswertung der V2X-Meldungen (1. und Abschlussdemonstration)
- Änderungsdetektion und Selbstaktualisierung hochgenauer Karten
- Smartphone Aufbau und Funktionsweise

Im Folgenden werden die Live-Demonstrationen je Anwendungsszenario und Partner beschrieben:**Anwendungsszenario Landmarken:** Es gibt viele Objekte, die automatisierten Fahrzeugen als Landmarken dienen können (Lichtmasten, Ampeln, Schilder, Kanaldeckel, Fahrspurmarkierungen, Ampelmasten, Poller, Häuserecken, Bäume). Durch Orientierung an diesen Objekten kann eine deutlich genauere Ortung als nur mit GPS (und auch D-GPS) durchgeführt werden. Dazu müssen diese hochgenau vermessenen Objekte in den Kartendaten der Fahrzeuge aufgenommen werden. In SAFARI werden diese Objekte aus dem im Berliner VISS übernommen. Dazu muss aber auch regelmäßig sichergestellt werden, dass diese hochgenau vermessenen Objekte regelmäßig in den Kartendaten des VISS aktualisiert werden. Dies geht nur mit einem automatisierten Prozess, dessen erster Teil demonstriert werden kann.

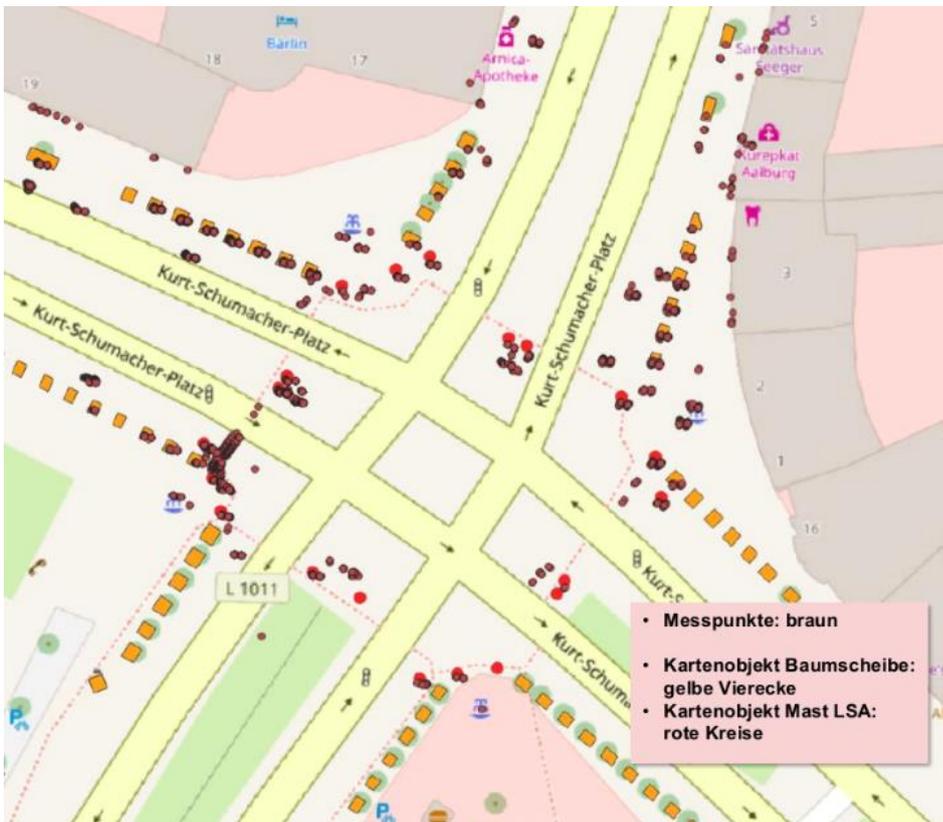


Abbildung 2-29: Anwendungsszenario Landmarken (Darstellung der IAV)

Anwendungsszenario Verkehrszeichen: Das Land Berlin arbeitet intensiv an der Digitalisierung der Verwaltungsprozesse auch im Bereich Verkehrsmanagement. SAFARI versucht dem Traum der Verantwortlichen näherzukommen, alle Veränderungen in der Verkehrsinfrastruktur möglichst zeitnah auch in den digitalen Datenbestand zu übernehmen. Aber auch z.B. tagesgenau über den Zustand aller Baustellen unterrichtet zu sein, erfordert derzeit viel Rechercharbeit.

SAFARI trägt hierzu mit der Erkennung der aktuell im Straßenraum befindlichen Absperrungen, Baken und Verkehrszeichen bei. Im Abgleich mit den im Berliner VISS vorhandenen Daten können die tatsächlich vorhandenen Verkehrszeichen oder auch Baustellen leicht in der digitalen Karte aktualisiert werden.

Anwendungsszenario Parken: Es werden unterschiedliche Ansätze zur Ermittlung freier Parkplätze gezeigt. Auf der Grundlage der Kartendaten ist bekannt, an welchen Stellen ein Fahrzeug legal parken darf. Je nach Versuchsträger werden entweder direkt die Freiflächen oder aber die Fahrzeuge auf diesen Parkflächen detektiert.

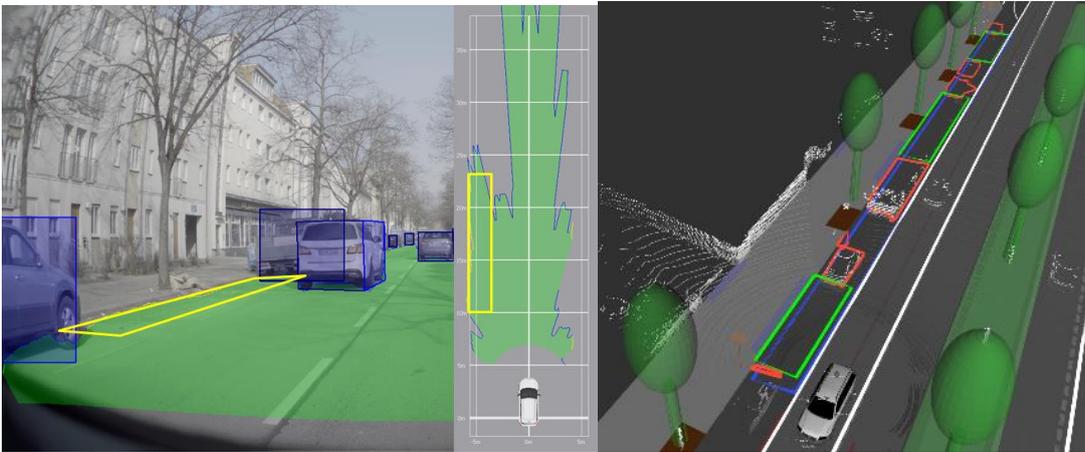


Abbildung 2-30: Anwendungsszenario Parken (links: HELLA Aglaia, rechts: DCMLR/FU)

Anwendungsszenario Baustellen: Bei der Vorbeifahrt an einer Baustelle werden von den Versuchsträgern (DCAIT1, HELLA Aglaia) Baustellenbaken erkannt, aus denen unmittelbar nach der Passage mittels einer Voranalyse die flächenmäßige Ausdehnung der Baustelle approximativ bestimmt und im Fahrzeug visualisiert wird.



Abbildung 2-31: Anwendungsfall Baustelle (Demonstration HELLA Aglaia)

Anwendungsszenario Green Light Optimal Speed Advisory (GLOSA): Erstmals können auch Berliner Ampeln die für einen GLOSA-Service notwendigen Informationen versenden, die sog. SPAT/MAP Nachrichten (vorerst nur im ETSI G5 p-WLAN). Diese Services können sowohl als OEM-Services (Daimler, AUDI, BMW, et.al.) als auch als App-basierter Services für alle umgesetzt werden.

Anwendungsfall Lichtsignalanlage: Im Straßenraum des Landes Berlin gibt es viele Lichtsignalanlagen, die zur Verkehrsbeeinflussung genutzt werden. Für zukünftige autonome Fahrzeuge ist es essentiell die Signalkörper als auch den aktuellen Zustand der Ampel zu ermitteln. Darüber hinaus ermöglicht dies auch eine Verifikation der per V2X Kommunikation übertragenen Information.

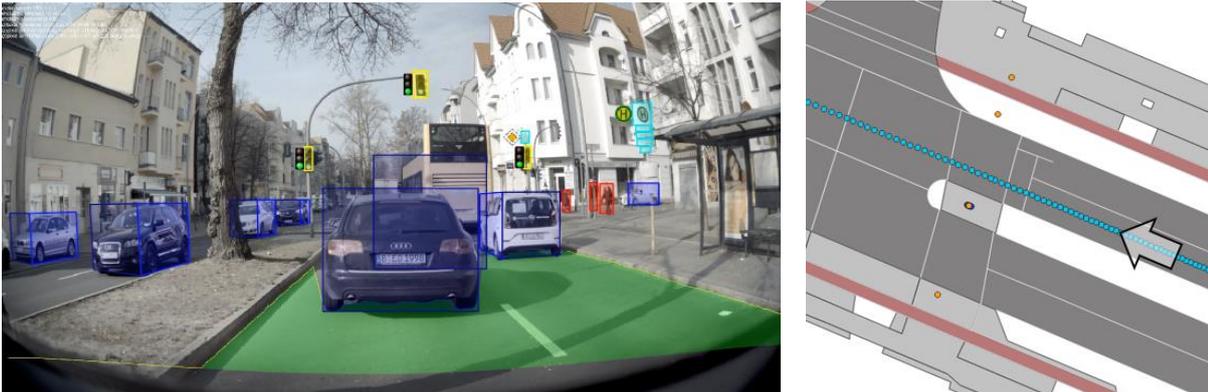


Abbildung 2-32: Anwendungsfall Lichtsignalanlage (Demonstration HELLA Aglaia)

Demo DCAITI: Im Fahrzeug des DCAITI wurde die Perzeption verschiedener Objekte mit 3D-Vision (bestehend aus einem Multi-Kamera-System und LiDAR) gezeigt.

Bezüglich des Use-cases Parkens wurde auf die Detektion von parkenden Fahrzeugen mit verschiedenen Sensoren auf der Fahrt entlang den Straßen des Testfeldes hingewiesen.

Das DCAITI visualisierte die parkenden Objekte der Klasse "Car", die Parkflächen der digitalen Karte des Landes Berlin wurden als grüne Polygone dargestellt, wobei sich die freien Parkräume implizit ergaben (siehe Abbildung).

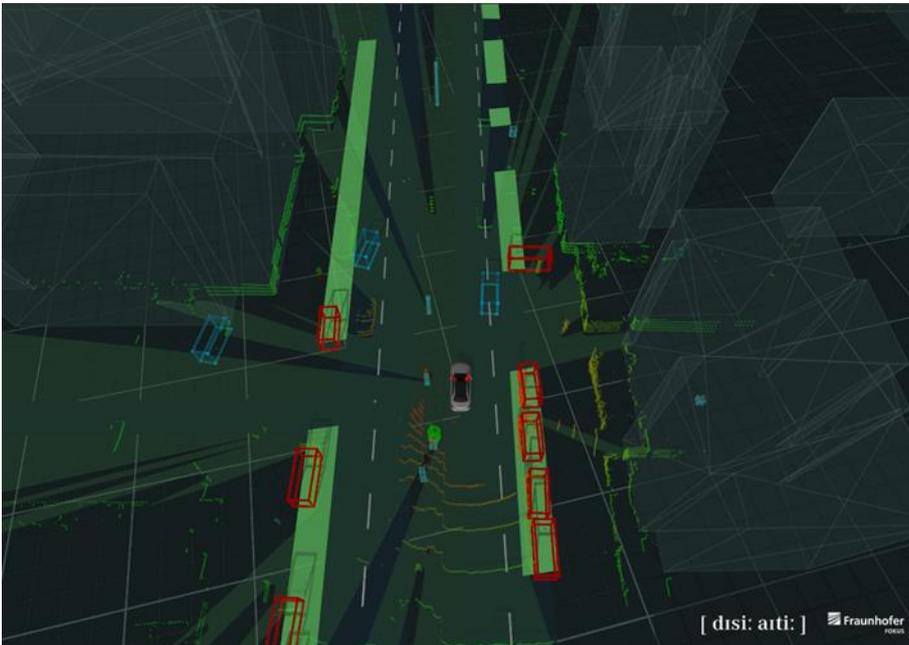


Abbildung 2-33: Demonstration DCAITI

Smartphone-Demo im Bus: Zur Demonstration der Smartphone-Anwendung der FOKUS wurde von der BVG ein Bus zur Verfügung gestellt. Dort wurde dem Fachpublikum der Aufbau der Smartphone Halterung erläutert sowie mit einem Video die Funktionsweise der App-Komponenten demonstriert.

Demo FOKUS: Im Fahrzeug von FOKUS wurde der GLOSA-Service demonstriert.

Bei der Vorbeifahrt an den im Testfeld bereits mit V2X-fähigen LSA wurde der Service live auf einem Display gezeigt (Fahrt entlang der äußeren Straßen des Testfeldes).

Demo DCMLR/FU: Das DCMLR demonstrierte das autonome Fahren und gleichzeitig die Erkennung von freien Parkplätzen und die Selbstlokalisierung anhand von Landmarken mit Laserscannern (DCMLR/FU Technologie) sowie eine Änderungsdetektion auf dem Fahrzeug.

Für die Erkennung von freien Parkplätzen erkannte die seriennahe Sensorik auf der Fahrt entlang den Straßen des Testfeldes Freiräume und verschnitt die Daten direkt auf dem Fahrzeug mit der digitalen Karte des Landes Berlin auf dem Fahrzeug.

Als Landmarken wurden im Fahrzeug z.B. Lichtmasten, Straßenmobiliar und Bäume erkannt.

Im Abgleich mit der digitalen Karte des Landes Berlin wurden auf dem Fahrzeug die Abweichung zwischen detektierten Landmarken und den Kartendaten visualisiert (online auf Monitor verfolgbar).

Die Korrektur der Positionierung wurde anhand eines visuellen Vergleichs zwischen der GPS-Position und der Positionsbestimmung anhand von Landmarken demonstriert (online auf Monitor verfolgbar).

Demo HELLA Aglaia: Neben dem Anwendungsfall Parken konnten auch die Fälle Lichtsignalanlage, Baustelle und Landmarken im Fahrzeug demonstriert werden. Hierzu wurden z.B. die Verkehrszeichen entlang der gefahrenen Strecke erkannt (z.B. Baken in der Ollenhauerstraße, die vor einer Verschwenkung eines Fahrradweges warnen, Baustellenbaken, Fahrspurmarkierungen, Ampel mit aktuellem Zustand und Verkehrszeichen mit Typ des Zeichens), identifiziert und in Echtzeit an das Backend gemeldet. Weiterhin wurden die erkannten Freiräume und Objekte wurden im Fahrzeug visualisiert (Monitor).

Im Use Case Landmarken lokalisierte sich das Fahrzeug basierend auf den Karten der Senatsverwaltung. Hierzu wurden neben den oben genannten Objekten zusätzliche Objekte wie z.B. Kanaldeckel und Abbiegepeile detektiert und ein Abgleich mit den Karten der Senatsverwaltung durchgeführt.



Abbildung 2-34 Objekt- und Freiraumerkennung der HELLA Aglaia Kamera

Demo IAV: Im Fahrzeug der IAV wurden die empfangenen V2X-Nachrichten, die die Grundlage des GLOSA-Service bieten, detailliert aufgeschlüsselt und erläutert. Dabei wurden sowohl Kamera-, Positions- als auch V2X-Daten aufgenommen und im Fahrzeug angezeigt.

Bei der Vorbeifahrt an den im Testfeld bereits mit V2X-fähigen LSA wurden die empfangenen Nachrichten auf einem Display gezeigt (Fahrt entlang der äußeren Straßen des Testfeldes).

2.7.3 AP 7.3 Eigenevaluation

Zum Abschluss des Projekts wurden die Ergebnisse anhand der erzeugten Daten evaluiert. Dabei wurde versucht, mit den verschiedenen VT möglichst gleichzeitig Daten zu akquirieren. So konnte eine Evaluation der VISS-Karte im Vergleich zur Ground Truth, der von den RSU im Testfeld verschickten Nachrichten, der Selbstlokalisierungsverfahren von DCAITI, HELLA Aglaia und DCMLR/FU sowie eine exemplarische Evaluation der Änderungsdetektion des Backend durchgeführt werden.

Es wurde eine Evaluation der VISS-Karte, der von den RSU im Testfeld verschickten Nachrichten, der Selbstlokalisierungsverfahren von DCAITI, HELLA Aglaia und DCMLR/FU sowie eine exemplarische Evaluation der Änderungsdetektion des Backend abschließend zum Projekt durchgeführt.

Ein Ergebnis der Evaluation ist, dass die VISS-Karte seit ihrer Erstellung einige grobe Fehler enthält, insbesondere bei den Fahrbahnen, Bordsteinen und Fahrbahnmarkierungen in einem Teilbereich des Testgebiets. Es finden sich auch einige Kartenelemente, die seit ihrer Aufnahme in die VISS-Karte zu unterschiedlichen Zeitpunkten eine Veränderung erfahren haben. Auch konnte das Fehlen einiger Kartenelemente und es konnten Inkonsistenzen in der Karte nachgewiesen werden.

Die von den Partnern entwickelten Selbstlokalisierungsverfahren mit Verwendung der VISS-Karte sind nachweislich mindestens Fahrspur-genau und um Größenordnungen genauer, als eine rein GPS basierte Lokalisierung, selbst dann, wenn die Lokalisierung mit einem sehr genauen GNSS-Navigationssystem durchgeführt wird.

Die Änderungsdetektion des Backend konnte neue, nicht in der VISS-Karte verzeichnete Elemente aufzeigen. Die Veränderungsdetektion war zudem in der Lage das Verschwinden, also das mögliche Fehlen von Objekten in der Realität gegenüber der Karte, anzuzeigen. Auch wurden Änderungen in der Position von Kartenelementen gegenüber den entsprechenden Objekten in der Realität nachgewiesen. Unter Verwendung einfacher Freiraumpolygone konnte im Backend eine Detektion freier Parkplätze erfolgreich demonstriert werden.

Die von den RSU verschickten SPaT/Map-Nachrichten wurden hinsichtlich ihrer Empfangbarkeit evaluiert. Die Nachrichten einiger RSU's sind in sehr großen Entfernungen (über 500 m, bis 1 km) noch gut empfangbar. Alle Stationen erreichen eine Empfangbarkeit der Nachrichten in der üblichen Mindestentfernung von 300 m.

3 Vergleich Planung und Umsetzung des Vorhabens

3.1 Arbeitsplanung

Das Vorhaben war ursprünglich auf 25 Monate Dauer ausgelegt. Das Projektkonsortium hat im zweiten Umsetzungsjahr mehrere Schwerpunkte identifiziert, für welche nur bei einer Verlängerung die angestrebten Forschungsergebnisse erzielt werden konnten. Diese wurden mit den Auswirkungen auf den Zeit- und Arbeitsplan detailliert beschrieben und als Antrag auf Verlängerung beim Projektträger eingereicht. Diese Angaben sind hier aus Sicht des Projektabschlusses aktualisiert und beschreiben die wichtigsten Abweichungen von der Arbeitsplanung. Zu beachten ist dabei, dass der Partner IAV seine geplanten Arbeiten innerhalb der 25 Monate fertigstellen konnte und deshalb keinen Antrag auf Verlängerung stellte. Dadurch musste teilweise die AP-Leitung durch die verbliebenen Partner übernommen werden.

Die Verlängerung betraf auch die übergreifenden AP 1 Projektmanagement und Ergebnisverbreitung und AP 2 insbesondere AP 2.3 Technische Koordinierung.

3.1.1 Erprobung der Anwendungen auf Basis LSA-seitiger Roadside Units

Der Aufbau der RSU hat sich verzögert, so dass für die angestrebte Untersuchung der Erkennung des Lichtsignalgebers unter Berücksichtigung der ausgesendeten SPAT/MAP Meldungen nur bei einer Verlängerung eine ausreichende Datenlage erzeugt und ausgewertet werden kann. Ursache ist hier insbesondere die für jeden im Testfeld vertretenen LSA-Lieferanten speziell für das Land Berlin zu erarbeitenden Sicherheitsbetrachtungen.

Für die Untersuchung der alternativen Cellular-V2X Kommunikation mit einem vergleichenden Test der Technologien WLAN 80211p und C-V2X (Kommunikation mit LTE-V2X – PC5 Technologie) sollten ab Mai 2019 entsprechende Module zur Verfügung stehen. Mit der Verlängerung hoffte das Konsortium hierzu, noch eine Ausstattung zu erreichen und entsprechende Tests durchführen zu können. Es wurden jedoch trotz intensiver Bemühungen keine entsprechenden Module angeboten (keine Serienprodukte verfügbar).

Zudem war geplant, für die Erprobung eines GLOSA-Service unter Verwendung der RSU und der Multi Access Edge Computing Umgebung (MEC) der Telekom einen längeren Testzeitraum zur Verfügung zu haben. Für GLOSA-Services, welche auf p-WLAN ausgesendeten V2X-Meldungen beruhen, traf das auch entsprechend ein. Allerdings konnte nicht rechtzeitig die Abstimmung über die Sicherheitsbetrachtung, die für die Aussendung der entsprechenden V2X-Meldungen per LTE-Modem notwendig war, abgeschlossen werden.

3.1.2 Erprobung von Small Cells

Auch für die Small Cells sind Verzögerungen bei der Planung und Anbringung eingetreten. Damit konnten diese bei einer Projektverlängerung ebenfalls länger getestet werden (insbesondere Übergabe der Kommunikation (Handover) zwischen Macro Cells und Small Cells, erreichbarer Datendurchsatz und Coverage).

3.1.3 Datenerfassung im Fahrzeug

Die Planung und Umsetzung der Datenerfassung mit den Versuchsträgern konnten bei den einzelnen Partnern bedingt durch die späte Planungssicherheit (vorliegen des schriftlichen Bescheids) erst verspätet erfolgen. Da die entsprechenden Festlegungen durch alle Partner gemeinschaftlich getroffen wurden, hat dies den Beginn der Datenakquise im endgültigen für die Weiterentwicklungen notwendigen Maß verzögert. Die sukzessive Verbesserung der Datenerfassung ist um ca. 4 Monate verzögert. Mit einer Verlängerung wurde es möglich, die Erfassungsalgorithmen wie geplant zu verbessern.

Zudem erfolgten aufgrund der extrem trockenen Witterungsbedingungen des Jahres 2018 zu wenig Aufnahmefahrten bei Regen, Schnee oder Nebel.

3.1.4 Digitalisierung und Integration der Verwaltungsprozesse

Der Zeitverzug im Projekt wirkte sich vor allem auf Datenbewertungen aus, die eine weitere Optimierung der Datenakquise und der Algorithmen im Backend ermöglichen.

Die für die Untersuchung der weiteren Digitalisierung der Verwaltungsprozesse notwendigen Daten aus der SAFARI Änderungsdetektion standen erst später zur Verfügung als geplant. Nachdem die entsprechende Umgebung rechtzeitig zur Verfügung gestellt werden konnte, traten bei der Detailabstimmung der Eingangsdaten Verzögerungen auf, die auch die Anlernphase der Algorithmen und damit die Bereitstellung der Ergebnisse an die Verwaltung betreffen.

Mit einer Verlängerung wurde es möglich die Übergabe und Mechanismen der Weiterverarbeitung der Daten genauer zu untersuchen.

3.1.5 Weiterentwicklung der Smartphone-App

Es gab Verzögerungen bei den Verhandlungen mit der BVG (bzw. BT) zur Ausrüstung von Bussen mit Geräten zur Datenerfassung (Smartphones), so dass das Einfahren von BVG Daten erst im Januar 2019 starten konnte. Daher mussten verschiedene Arbeiten zur Weiterentwicklung der App

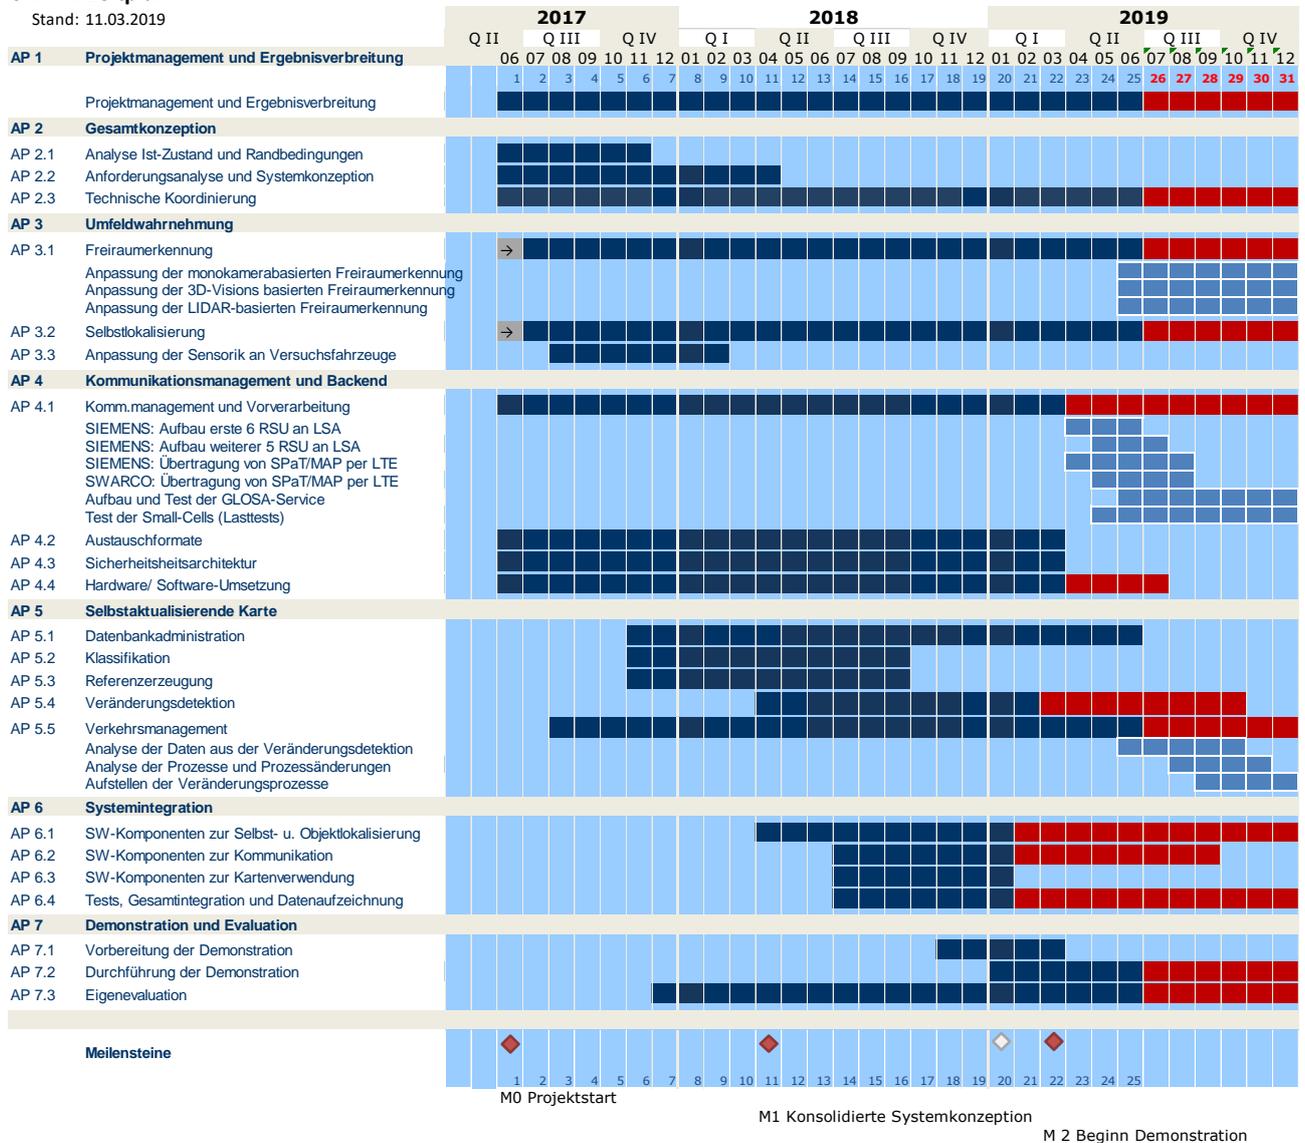
und Auswertung nach hinten verschoben werden. Durch die Verlängerung konnte die verzögerte Entwicklung aufgeholt werden und eine weitere Messkampagne mit der BVG / BT durchgeführt werden. Es wurde ein Unterauftrag an die BT vergeben, um deren Kosten z.B. bei der Freistellung der Busfahrer zur Einweisung in den Gebrauch der App zu decken.

3.2 Zeitplanung

Zum Zeitpunkt der Beantragung wurde folgender Zeitplananpassung geplant, der dann im Zuge der Projektverlängerung angepasst wurde. Er konnte im Wesentlichen eingehalten werden konnte:

SAFARI Zeitplan

Stand: 11.03.2019



4 Ziele des Vorhabens

4.1 Relevante F&E-Ergebnisse Dritter

In verschiedenen Projekten wird die Sensorik autonomer Fahrzeuge und insbesondere die infrastrukturelle Unterstützung autonomer Fahrfunktionen erforscht.

Eine hochgenaue Selbstlokalisierung ist dabei eine der unverzichtbaren Basisfunktionen eines autonomen Fahrzeuges. Hierfür werden oft satellitenbasierte Lokalisierungssysteme (engl.: Global Navigation Satellite System, Abk.: GNSS) eingesetzt, die sich jedoch in dicht bebauten innerstädtischen Bereichen als unzureichend erwiesen haben, da durch Reflexionen (multi-path) des GNSS-Signals an Gebäuden die Lokalisierungsqualität verringert wird. Es existieren Ansätze zur Verbesserung der Positionierungsgenauigkeit in urbanen Bereichen. Wie etwa in einer Studie der ANavS GmbH, in der untersucht wurde wie mit Hilfe von zwei Multi-GNSS-Empfängern, einem Inertialsensor, einer visuellen Positionierung, der Odometrie und zusätzlicher Vehicle-to-Infrastructure(V2I)- und Vehicle-to-Vehicle(V2V)-Kommunikation für die Übertragung der Realtime-Kinematics (RTK) eine bessere Lokalisierungsqualität erreicht werden kann. Es existiert auch umfangreiche Forschung zur kooperativen Umfelderkennung mobiler Roboter, aber zumeist beschränkt sich diese auf kleinere Roboter oder Innenraumszenarien ("FastSLAM").

Durch die Verwendung von landmarkenbasierten Lokalisierungstechnologien, wie sie im Projekt SAFARI entwickelt wurden, lässt sich auch in solchen Bereichen eine hochgenaue Selbstlokalisierung erreichen. Landmarken-Lokalisierungssysteme setzen jedoch eine ausreichende Menge an Landmarken voraus, um ausreichend akkurate Ergebnisse zu liefern. Bislang wurden Regionen mit besonders geringer Landmarkendichte, wie Tunnel und Schnellstraßen, in der Erforschung landmarkenbasierter Lokalisierungstechnologien oft nicht behandelt oder es wurden künstliche Landmarken hinzugefügt. Insbesondere in Tunnelbereichen ist die Situation nicht zufriedenstellend, da dort auch kein GPS-Signal zur Verfügung steht.

Große Fortschritte in der Rechenkapazität und darauffolgende Aktivitäten der Wissenschaftscommunity haben in den letzten Jahren zu rasanten Fortschritten in bild-basierten Objektdetektionsverfahren geführt ("Fast R-CNN", "You only look once: Unified, real-time object detection", "SSD: Single Shot MultiBox Detector"). Die dabei entwickelten Netzwerkarchitekturen führen zusammen mit immer weiter fortgeschrittenen Trainingsalgorithmen zu einer sehr robusten Detektion von verkehrsrelevanten Objekten im automobilen Kontext und das unter diversen Licht- und Umweltbedingungen. Viel Fortschritt gab es ebenfalls bei dem Versuch, diese Algorithmen in Echtzeit auf mobilen Geräten mit geringer Leistung zu implementieren (Mobilenets und MobileNetV2), sodass mittlerweile leistungsfähige Objektdetektions-Algorithmen auf modernen automobilen Chips realisiert werden können.

Durch die jüngsten Entwicklungen und Fortschritte im Bereich der künstlichen Intelligenz (KI) rücken zunehmend Ansätze in den Fokus der Forschung, die Objekte wie Verkehrsampeln und -Schilder in Kamerabildern erkennen und klassifizieren und diese dann mit den in HD-Karten verzeichneten Positionen solcher Objekte zu vergleichen (u.a. in "Topological semantic mapping and localization in urban road scenarios" im Journal of Intelligent & Robotic Systems, 2018). Diese Systeme ermöglichen ebenfalls eine hochgenaue Positionsbestimmung bei relativ hoher Robustheit gegenüber wechselnden Licht- und Witterungsverhältnissen oder sonstigen Umgebungsveränderungen. Eine weiterhin bestehende Herausforderung für solche Ansätze sind Umgebungen mit wenig oder gar keinen Landmarken (z.B. in Tunneln).

Neben dem Projekt SAFARI beschäftigen sich auch die Projekte "Ikopa" und "DIGINET-PS" mit Perzeption, Lokalisierung und automatisiertem Fahren.

Es wird derzeit mit hoher Priorität an einem Abbild des lokalen Verkehrsgeschehens geforscht. Unter dem Stichwort der Local Dynamic Map werden derzeit noch verschiedene Konzepte erprobt, wie die Erfassung großer Räume erfolgen kann, wie die Daten verteilt und wieder genutzt werden können. Hier ist unter anderen das Projekt "Ko-PER" aus der Forschungsinitiative "Ko-FAS" zu nennen, welches ein kooperatives Umfeldmodell für Kreuzungsszenarien erforscht hat. Hierbei wurden die detektierten Verkehrsteilnehmer zwischen den Fahrzeugen verteilt, um Kollisionswarnungen für verdeckte Objekte generieren zu können. Die Projektergebnisse des "Ko-PER"-Projektes zeigen, dass eine kooperative Umfeldwahrnehmung via V2V möglich ist.

In mehreren Projekten - auch auf europäischer Ebene – wird an der Erprobung der Perzeption und Prädiktion (Umweltwahrnehmung) auch unter Nutzung der V2X-Kommunikation über ITS-G5 und Mobilfunk geforscht. Eine vollständige Leistungsbewertung der Anwendungen, die integrierte Konzepte für die Kooperation, den Informationsaustausch und die Kommunikation von Mischverkehren an innerstädtischen Knotenpunkten entwerfen, und insbesondere solcher Hybridnetzwerke steht jedoch noch aus. Studien zeigen, dass LTE zwar höhere Latenzzeiten als die Kommunikation über 802.11p erreicht, dafür jedoch eine bessere Skalierbarkeit und eine Kommunikation über große Entfernungen (bzw. weltweit) besitzt. Um die Latenzzeiten für Assistenzsysteme im Fahrzeug zu verringern, wird ein neuer Standard basierend auf LTE getestet, LTE-Vehicular (wurde im Rahmen des 3GPP Release 14 standardisiert). Dabei werden Mobilfunkmasten mit der Mobile Edge Computing-Technologie erweitert, die eine direkte Kommunikation innerhalb der lokalen Funkzelle ermöglicht, ohne dass die Informationen zunächst in das gesamte Netz gespeist werden. Dadurch werden Signallaufzeiten von bis zu 20 ms ermöglicht. LTE-V stellt eine Art Übergangstechnologie für die Zeit bis zum Release von 5G dar. Dieses soll ab 2020 flächendeckend verfügbar sein. Ende Dezember 2017 wurde von der 3GPP ein erster Standard dazu verabschiedet. Die 5G-Technologie verspricht Datenraten von bis zu 10

Gbit/s und Latenzzeiten von unter 1 ms. Einen großen Vorteil verspricht die Möglichkeit Ad-hoc-Netze aufbauen zu können, wie sie bereits über IEEE 802.11p möglich sind. An der Bereitstellung geeigneter V2X-Komponenten ab 2020 arbeiten Hersteller wie Siemens Mobility GmbH, Nordsys, Cohda Wireless und Linkbird.

Die Vernetzung von Fahrzeugen über V2X-Schnittstellen ermöglicht auch die Teilnahme an kooperativen Fahrmanövern. Kooperatives Verhalten im Sinne von individuellen Handlungen einzelner Fahrzeuge auf Basis gemeinsam erhobener Daten wurde beispielsweise im Rahmen des öffentlich geförderten Projekts KoHAF gezeigt und untersucht. Das EU-Projekt C-Road geht einen Schritt weiter, in dem es versucht, durch bestimmte Services Verkehrssituationen als Ganzes zu beeinflussen. Mit GLOSA wurde beispielsweise ein Service realisiert, der auf Basis der aktuellen und zukünftigen Ampelphasen Geschwindigkeitsempfehlungen für Fahrzeuge zur Verfügung stellt und dabei einen Grüne-Welle- oder Rote-Ampel-Assistent ermöglicht und somit insgesamt zu einem besseren Verkehrsfluss beiträgt. Im EU-Projekt CODECS wurde eine Systematik und Roadmap vorgeschlagen, die verschiedene V2X-Kommunikationsanwendungen anhand des angestrebten Kooperationsgrades unter einander in Bezug bringt.

An der Standardisierung der nächsten Generation von V2X-Kommunikation im Car-2-Car Communication Consortium sind auch die Partner DCAITI in Kooperation mit dem Fraunhofer FOKUS mittelbar beteiligt, die beide auch in wesentlichen Forschungsprojekten zum Thema Vernetzung von Fahrzeugen und Fahrzeugen mit Infrastruktur beteiligt waren (simTD, PRE-DRIVE C2X, DRIVE C2X, TEAM, Ikopa und aktuell IMAGinE).

Als weiteres V2X-Forschungsprojekt soll "HARMONIZEDD" erwähnt werden, das von April 2017 bis Juni 2019 im digitalen Testfeld Dresden durchgeführt wurde und Teil der Initiative "Synchrone Mobilität 2023 – Intelligente Verkehrssysteme in Sachsen" war. Hauptaugenmerk war die Erforschung des automatisierten und vernetzten Fahrens im Mischverkehr aus Fahrzeugen mit heterogener Technologieausstattung. Hierbei wurden auch Technologien wie ein Cloud-Backend, GLOSA oder kooperative Fahrmanöver erprobt. Jedoch hat dieses Projekt keine Forschung bezüglich der kontinuierlichen Aktualisierung hochgenauer Karten und der kooperativen Erstellung neuer Karten via SLAM getätigt. Auch gab es keine Forschung an einer der "Local Dynamic Map" vergleichbaren Technologie zur kooperativen Perzeption.

Die in vielen Kommunen zur Erleichterung der täglichen Arbeit erstellten digitalen, hochgenauen Karten (HD-Karten) werden derzeit noch mit in mühsamer Detailarbeit durch die Experten aktualisiert, auch wenn bei der messtechnischen Aufnahme und Aufbereitung der Daten weitestgehend teilautomatisierte Verfahren eingesetzt werden können. Viele bemühen sich um eine effektive Selbstaktualisierung, es ist hierzu jedoch aktuell keine für Berlin passende Lösung bekannt.

Die Erstellung und Verbreitung von digitalen Karten für das autonome Fahren werden in vielen auch europäischen Projekten erforscht. Dabei wird u.a. die Verwendung von Datenquellen vernetzter und zunehmend automatisierter Fahrzeuge betrachtet. Es sind noch keine skalierbaren Lösungen bekannt.

4.2 Änderungen der Zielsetzung

Im Verlauf des Vorhabens wurde keine Anpassung der Zielsetzung notwendig, jedoch wurden folgende zusätzliche Ziele gesetzt:

- Nach den ersten positiven Erfahrungen mit der monokamerabasierten Objekterfassung hat SenUVK einen kommunalen Versuchsträger (Fahrzeug des Bezirksamtes Reinickendorf) mit einem Erfassungssystem ausstatten lassen und in Testfahrten eingesetzt. Aufgrund der teilweise nicht zugänglichen Fahrzeuginformation konnte die Bewertung nur eingeschränkt durchgeführt werden. Ein erfolgsversprechendes flächendeckendes Einsatzszenario konnte so nicht abgeleitet werden.
- Ursprünglich war vorgesehen, die Smartphone-basierte Erfassung in allen Versuchsträgern der anderen Partner parallel mitlaufen zu lassen. Da die Daten aber nicht direkt vergleichbar sind, wurde zugunsten einer deutlich höheren Anzahl an eingefahrenen Daten eine Ausstattung von BVG Linienbussen angestrebt und durchgeführt (siehe auch Beschreibung in AP 3.4).

Abkürzungsverzeichnis

Abkürzung	Bedeutung
AVF	Automatisiertes und vernetztes Fahren
C2C CC	Car-2-Car Communication Consortium
DB	Datenbank
DSRC	Dedicated Short Range Communication
D-GNSS	Differential GNSS
DL	Downlink
EU	Europäische Union
GIS	Geographisches Informationssystem
GNSS	Global Navigation Satellite System
GPS	Global Positioning System
802.11p	"IEEE Std P802.11p-2010" IEEE Wireless Access for the Vehicular Environment, amendment to 802.11, included in "IEEE Std P802.11-2012"
IVS	Intelligente Verkehrssysteme
HD	High Definiton
LSA	Lichtsignalanlage
LTE	Long Term Evolution
Mbps	Mega bit per Second
MHz	Mega Hertz
NDS	Navigation Data Standard e.V.
MAP	auch TOPO genannte I2V Meldung mit Information zu Geometrie des Knotenpunktes
RSU	RoadSide Unit

Abkürzung	Bedeutung
SPaT	Signal Phase an Timing (I2V Meldung mit Information des LSA-Programmablaufs)
VT	Versuchsträger – Fahrzeug mit Sensorik für automatisiertes Fahren im Versuchsaufbau
V2V	vehicular-2-vehicular
V2I	vehicular-2-infrastructure
V2X	vehicular-2-everything
V2N	vehicular-2-network
V2P	vehicle-2-pedestrian (equivalent to VRU)
VRU	vulnerable road user
WFS	Web feature services
ZIP	Steht für das ZIP-Dateiformat (von englisch <i>zipper</i> ‚Reißverschluss‘). Erlaubt verlustfreie Kompression von Dateien und kann auch als Container mehrere zusammengehörige Dateien oder ganze Verzeichnisbäume zusammenfassen.
	Berlinspezifische Abkürzungen
FIS	Fachübergreifendes Informations-System (SenUVK/ SenSW)
IT DZ	IT Dienstleistungszentrum des Landes Berlin
VISS	Verkehrsinformationssystem Straße (als Organisation Geschäftsstelle Verkehrsinformationssystem Straße, SenUVK)
VIZ	Verkehrsinformationszentrale (durch VMZ GmbH betrieben)
VKRZ	Verkehrsregelungszentrale (durch VLB betrieben)
VLB	Verkehrslenkung Berlin (SenUVK nachgeordnete Behörde)

Berichtsblatt

1. ISBN oder ISSN	2. Berichtsart (Schlussbericht oder Veröffentlichung) Schlussbericht
3. Titel Verbundbericht SAFARI Gemeinsamer Sachbericht nach 6.2 ANBest-Gk	
4. Autor(en) [Name(n), Vorname(n)] Rosè, Helge, Fraunhofer FOKUS Ricci, Luca, SenUVK Bauling, Stefanie, SenWEB Strop, Oliver, scope Dörheit, Eric, DCAITI Bunk, Sebastien, DCAITI Kwella, Birgit, Fraunhofer FOKUS	5. Abschlussdatum des Vorhabens 31.12.2019 6. Veröffentlichungsdatum 20.04.2020 7. Form der Publikation pdf
8. Durchführende Institution(en) (Name, Adresse) Senatsverwaltung für Umwelt, Verkehr und Klimaschutz Berlin (SenUVK), Am Köllnischen Park 3, 10179 Berlin Senatsverwaltung für Wirtschaft, Energie und Betriebe (SenWEB), Martin-Luther-Straße 105, 10 825 Berlin Daimler Center for Automotive Information Technology Innovations (DCAITI), Ernst-Reuter-Platz 7, 10587 Berlin Fraunhofer Institut für Offene Kommunikationssysteme FOKUS, Kaiserin-Augusta-Allee 31, 10589 Berlin Freie Universität Berlin (FU Berlin), Arnimallee 7, 14195 Berlin HELLA Aglaia Mobile Vision GmbH, Ullsteinstraße 140, 12109 Berlin IAV GmbH Ingenieurgesellschaft Auto und Verkehr, Carnotstr. 1, 10587 Berlin	9. Ber. Nr. Durchführende Institution 03090251431 10. Förderkennzeichen 16AVF1029 11. Seitenzahl 98
12. Fördernde Institution (Name, Adresse) Bundesministerium für Verkehr und Digitale Infrastruktur (BMVI) Invalidenstraße 44 (Hauptsitz), 10115 Berlin	13. Literaturangaben Anzahl 15 14. Tabellen Anzahl 4 15. Abbildungen Anzahl 34
16. Zusätzliche Angaben -	
17. Vorgelegt bei (Titel, Ort, Datum) -	
18. Kurzfassung In dem Forschungsprojekt SAFARI erprobte das Land Berlin unter der Federführung der Senatsverwaltung für Umwelt, Verkehr und Klimaschutz (SenUVK) zusammen mit seinen Partnern den Austausch und die Aktualisierung digitaler Karten als eine der Grundvoraussetzungen für das automatisierte und vernetzte Fahren. Das Projekt wurde im Rahmen des Förderprogramms des BMVI, der „Strategie automatisiertes und vernetztes Fahren – Leitanbieter bleiben, Leitmarkt werden, Regelbetrieb einleiten“ (Strategie AVF), finanziell gefördert. Die Grenzen der Leistungsfähigkeit der Sensorik, die in den autonomen und automatisierten Fahrzeugen eingesetzt wird, wurden mithilfe einer Flotte von Testfahrzeugen getestet. Um die unterschiedlich eingesetzte Sensorik zu vergleichen, traten vollautomatisierte zum autonomen Fahren mit Sicherheitsfahrer lizenzierte Forschungsfahrzeuge, mit einem 360° 3D-Vision System oder mit der nächsten Generation von Serienmonokameratechnik ausgerüstete Fahrzeuge und Smartphones gegeneinander an. Die Fahrzeuge benutzen die verfügbaren Kartendaten für die Selbstlokalisierung und als Referenzdaten für die Objekterkennung. Die detektierten Objekte werden der Änderungsdetektion des Backend übergeben und das Ergebnis wird der Karte zurück geliefert. Werden die neuen Daten der Karte stetig den Fahrzeugen zur Verfügung gestellt, erfolgt eine kontinuierliche Selbstaktualisierung der Karteninformation. Dazu werden fast nebenbei Informationen wie die Erkennung freier Parkplätze auf der Straßenseite oder die Erkennung einer neuen Baustelle generiert. SAFARI richtete den Fokus auf die Überprüfung der Objekterkennung und Änderungsdetektion und auf die Digitalisierung des Verwaltungsprozesses. Die Untersuchung der Kommunikation von Infrastruktur zu Fahrzeugen konzentrierte sich auf verschiedene Services, die dazu beitragen, den Verkehr effizient und sicher zu gestalten, wie zum Beispiel den GLOSA-Service. Neben der SenUVK Berlin beteiligten sich an dem Vorhaben SAFARI weitere Akteure der öffentlichen Hand (Senatsverwaltung für Wirtschaft, Energie und Betriebe, Verkehrslenkung Berlin, Bezirksamt Reinickendorf), Universitäten und Forschungseinrichtungen (Dahlem Center for Machine Learning and Robotics der Freien Universität Berlin, Fraunhofer Institut für Offene Kommunikationssysteme (FOKUS), Technische Universität Berlin mit dem Daimler Center for Automotive IT Innovations (DCAITI)) und Wirtschaftsunternehmen (IAV GmbH, HELLA Aglaia Mobile Vision GmbH, Deutsche Telekom AG).	
19. Schlagwörter	
20. Verlag -	21. Preis -

Document Control Sheet

1. ISBN or ISSN	2. Type of document (e.g. report, publication) final report	
3. Title Composite report SAFARI Joint factual report according to 6.2 ANBest-Gk		
4. author(s) (family name, first name(s), name of company)	Rosè, Helge, Fraunhofer FOKUS Ritter, Claas-Norman, FU Berlin Ricci, Luca, SenUVK Bauling, Stefanie, SenWEB Strop, Oliver, scope Dörheit, Eric, DCAITI Bunk, Sebastian, DCAITI Kwella, Birgit, Fraunhofer FOKUS	5. end of project 31.12.2019 6. publication date 20.04.2020 7. form of publication pdf
8. performing organization(s) (name, address)	9. originator's report no. 03090251431 10. reference no. 16AVF1029 11. no. of pages 98	
12. sponsoring agency (name, address)	13. no. of references 15 14. no. of tables 4 15. no. of figures 34	
16. supplementary notes -		
17. presented at (title, place, date) -		
18. abstract <p>The research project SAFARI focused on the exchange and updating of digital HD maps as a fundamental requirement for automated and connected driving. The project was part of the funding program of BMVI which promoted Connected and Automated Driving („Strategie automatisiertes und vernetztes Fahren – Leitanbieter bleiben, Leitmarkt werden, Regelbetrieb einleiten “(Strategie AVF).</p> <p>Within SAFARI, the limits of the performance of the sensors used in autonomous and automated vehicles have been tested using a fleet of testing vehicles. In this process, fully automated research vehicles licensed to autonomous driving with a security driver, vehicles equipped with 360°- 3D-Vision sets or the next generation of serial mono-cameras and smartphones competed against each other. The vehicles used the provided map data for their self-localisation and as reference data for the object detection. The detected objects were provided to a backend change detection (detected objects changes) and the results were fed back to the map. When the new map is provided to the vehicles a continuous self-updating of the map content is set up. Additionally, information such as free parking slots on the side of the road or the checking of a recently established construction site are generated nearly incidentally. SAFARI concentrated on the verification of the detected objects and changes and the digitalization of the verification process. The examination of the communication from infrastructure to vehicle concentrated on the many opportunities this communication offers to gain an efficient and safe regulation of traffic, e.g. via GLOSA-Service. Under the leadership of the Senate Department for Environment, Traffic and Climate Protection (SenUVK) the following organizations participated in the project SAFARI:</p> <ul style="list-style-type: none"> - public organizations - Senate of Berlin Department for Economics, Energy and Public Enterprises, Berlin traffic control, district Reinickendorf - universities and research institutes - Dahlem Center for Machine Learning and Robotics der Freien Universität Berlin, Fraunhofer Institute for Open Communication Systems (FOKUS), Technische Universität Berlin mit dem Daimler Center for Automotive IT Innovations (DCAITI) and - private enterprises - IAV GmbH, HELLA Aglaia Mobile Vision GmbH, Deutsche Telekom AG. 		
19. keywords		
20. publisher	21. price	