

KULAR

OPTISCHE KI-BASIERTE UMFELDWAHRNEHMUNG UND LOKALISIERUNG FÜR AUTOMATISIERTE FAHRZEUGE

Vorhaben aus dem Programm „Neue Fahrzeug- und Systemtechnologien“

Förderkennzeichen 19A22003

Schlussbericht

confidential vertraulich **restricted** beschränkt **public** öffentlich

28. November 2025



**Finanziert von der
Europäischen Union**
NextGenerationEU

Gefördert durch:



Bundesministerium
für Wirtschaft
und Energie

aufgrund eines Beschlusses
des Deutschen Bundestages

Inhaltsverzeichnis

I. Kurze Darstellung	4
1. Aufgabenstellung	4
2. Voraussetzungen, unter denen das Vorhaben durchgeführt wurde	6
3. Planung und Ablauf des Vorhabens	6
4. Wissenschaftlicher und technischer Stand, an den angeknüpft wurde	7
4.1. Angabe bekannter Konstruktionen, Verfahren und Schutzrechte, die für die Durchführung des Vorhabens benutzt wurden	8
4.2. Angabe der verwendeten Fachliteratur sowie der benutzten Informations- und Dokumentationsdienste	8
5. Zusammenarbeit mit anderen Stellen	9
II. Eingehende Darstellung	10
1. Verwendung der Zuwendung und erzieltes Ergebnis im Einzelnen, mit Gegenüberstellung der vorgegebenen Ziele	10
1.1. Arbeitspakete	10
AP 1. Projektkoordination	10
AP 2. Konzeptionierung und Spezifikation	12
AP 3. Konstruktion und Aufbau	13
AP 4. Fahrversuche und Datengewinnung	14
AP 5. Implementierung Relativortung	15
AP 6. Implementierung Absolutortung und Sensorfusion	17
AP 7. Referenzdatenoptimierung	18
AP 8. Implementierung Fahrzeugführung und Manöverplanung	18
AP 9. Gesamt-Systemintegration und Demonstration	19
AP 10. Evaluation und Publikation	19
1.2. Beiträge der einzelnen Partner	19
1.2.1. iMAR Navigation GmbH	19
1.2.1.1. Modulare Sensorplattform	19
1.2.1.2. Transfer von Forschungsergebnissen	21
1.2.1.3. Verifikation von Lokalisierungslösungen im GNSS-denied-Umfeld	21
1.2.1.4. Datenakquisition in diversitären Verkehrsszenarien	23
1.2.2. Valeo Schalter und Sensoren GmbH	25
1.2.2.1. Aufbau und Erweiterung der Versuchsträger	25

1.2.2.2.	Aufbau einer Visualisierung von hochgenauen Karten	26
1.2.2.3.	Analyse zu systematischen Fehlermoden	30
1.2.2.4.	Aufbau eines Modells für Kartendaten und Sensordaten	41
1.2.3.	DLR	58
1.2.3.1.	Aufbau und Erweiterung der Versuchsträger	58
1.2.3.2.	Spezifikation und Umsetzung der HD-Umgebungskartierung	60
1.2.3.3.	LiDAR-Navigation mit Punktwolkenkarten	63
1.2.3.4.	Segmentierung von LiDAR-Punktwolken	64
1.2.3.5.	Automatisiertes Lernen von Fahrstreifen	65
1.2.3.6.	Semi-Automatisiertes Kalibrierverfahren	69
1.2.3.7.	Versuchsdurchführung und Evaluation	72
1.2.4.	Universität Göttingen	74
1.2.4.1.	Punktwolkenregistrierung mittels Gauß-Wassersteindistanzen	74
1.2.4.2.	Integration von Straßennetzkarten	76
1.2.4.3.	Integration von Gebäudekarten	77
1.2.4.4.	Lidar-Odometrie Datensatz: Odyssey	78
1.2.4.5.	Graphenbasierte LiDAR-Odometrie	79
1.2.4.6.	Untersuchungen zu LiDAR Clustering	80
1.2.4.7.	Integration der UGOE-Algorithmen in die Live-Anwendung	80
1.2.4.8.	Nacht des Wissens ins Göttingen	81
1.3.	Gegenüberstellung zu den vorgegebenen Zielen	82
1.3.1.	iMAR Navigation GmbH	82
1.3.2.	Valeo Schalter und Sensoren GmbH	82
1.3.3.	DLR	83
1.3.4.	Universität Göttingen	84
2.	Wichtigste Positionen des zahlenmäßigen Nachweises	84
3.	Notwendigkeit und Angemessenheit der geleisteten Arbeit	84
4.	Voraussichtlicher Nutzen, insbesondere die Verwertbarkeit des Ergebnisses im Sinne des fortgeschriebenen Verwertungsplans	85
4.1.	iMAR Navigation GmbH	85
4.2.	Valeo Schalter und Sensoren GmbH	85
4.3.	DLR	87
4.4.	Universität Göttingen	88
5.	Während der Durchführung des Vorhabens dem ZE bekannt gewordener Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen	89
6.	Erfolgte oder geplante Veröffentlichungen des Ergebnisses	89
Literaturverzeichnis		90

I. Kurze Darstellung

1. Aufgabenstellung

Das Projekt OKULAR adressiert die genaue, robuste und ausfallsichere Positionierung für die Navigation von Fahrzeugen der SAE-Automatisierungsstufen 4 und 5. Da hierzu eine ausschließlich GNSS-basierte Positionierung nicht hinreichend ist, sollen mithilfe von Kamerabildern und weiteren Umfeldsensoren die Begrenzungen der Straße bzw. Fahrspur erkannt und das Fahrzeug sowohl relativ zur Fahrspur als auch in absoluten geodätischen Koordinaten präzise lokalisiert werden. Im Projekt OKULAR sollen Lösungen für in der Praxis bedeutende Szenarien herausgearbeitet werden, bei denen aktuell verfügbare Systeme bekannterweise versagen. Eine zentrale Lösungskomponente sind KI-basierte Verfahren, z.B. zur semantischen Segmentierung von Bilddaten für die Erkennung des Fahrzeugumfelds und zur kontextabhängigen Fusion von Daten aus verschiedenen Quellen. Die Einbindung von GNSS und Kartendaten soll eine absolute Lokalisierung ermöglichen, wobei das Ziel eine insgesamt höhere Genauigkeit und Robustheit im Vergleich zu alleinigem GNSS ist. Das Ergebnis ist eine Lokalisierungslösung als Plug&Drive-Box, kompatibel zu GNSS/INS-Ausgaben (Position, Geschwindigkeit, Kurswinkel), welche für die Führung eines Fahrzeugs geeignet ist. Basierend auf der Lokalisierung ist es möglich, Informationen aus einer zur Verfügung stehenden hochauflösenden Karte zu verwenden. Diese soll insbesondere das mithilfe fahrzeuglokaler Sensoren erstellte Umgebungsmodell verbessern und mit zusätzlichen Informationen anreichern. Die Demonstration erfolgt quantitativ unter Verwendung von Versuchsanlagen (Fahrzeuge und Verkehrsinfrastruktur) des DLR, Valeo und iMAR.

Teilprojekt iMAR Navigation GmbH: Konsortialführung und Entwicklung einer Lokalisierungsplattform für GNSS-denied Umgebungen

Als Konsortialführer übernimmt die iMAR Navigation GmbH federführend die organisatorische Projektabwicklung sowie die Koordination mit den beteiligten Projektpartnern. Inhaltlich adressiert das Unternehmen das Themenfeld der LiDAR-basierten Lokalisierung im GNSS-denied-Umfeld. Hierzu wird im Rahmen des Projekts eine dedizierte, modular aufgebaute Sensorplattform entwickelt, die neben der Inertialsensorik auch optische Messsysteme wie Kameras und LiDAR integriert. Das Gesamtsystem – bestehend aus Fahrzeugrechner, Referenzmesstechnik und ergänzender Peripherie – wird über die gesamte Projektlaufzeit hinweg eingesetzt, um das Konsortium mit einer breiten und diversifizierten Datengrundlage aus unterschiedlichen Verkehrsszenarien zu versorgen. Darüber hinaus strebt die iMAR Navigation GmbH die algorithmische Integration aktueller LiDAR-SLAM-Forschungsansätze in die bestehende Sensorsordatenfusionsarchitektur an, um eine konsistente Verarbeitung sowohl in Echtzeit- als auch in Post-Processing-Anwendungen im automotiven und industriellen Umfeld zu ermöglichen.

Teilprojekt Valeo Schalter und Sensoren GmbH: Fahrzeug-Umfelderfassung mit HD Karten

Im Projekt OKULAR setzt Valeo den Fokus auf die Nutzung der Lokalisierung in Kombination mit hochgenauen Karten in der Fahrzeug-Umfelderfassung. Hierbei werden Methoden zur Fusion von Daten aus fahrzeugfesten Sensoren und den Informationen aus hochgenauen Karten erforscht und entwickelt, welche die Qualität des sensorbasierten Umfeldmodells verbessern soll. Ein weiterer Fokus wird im Projekt auf die Kartenqualität selbst gesetzt. Hierzu wird Valeo einen Versuchsträger (VW ID.4) konfigurieren, welcher mit einem Satz modernster Valeo- Sensoren zur Umfelderfassung ausgestattet ist. Mit diesem soll die Verwendung von hochgenauen Karten bei niedrigen, mittleren und hohen Geschwindigkeiten untersucht werden. Die erforderlichen digitalen Karten werden durch Unterbeauftragung an einen kompetenten Kartenhersteller gemäß einer während der Projektlaufzeit durch Valeo und iMAR zu erstellenden Anforderungsspezifikation beschafft.

Teilprojekt DLR: Grenzfälle der optischen Lokalisierung, Validierung mit Referenzdaten und Auswirkungen auf das Fahrverhalten

Im Projekt OKULAR entwickelt das DLR Software, um die eigenen Forschungsfahrzeuge zu einer optischen Lokalisierung zu befähigen. Die Lösungskomponente des DLR kann u.a. als Weiterentwicklung optischer Spurhaltesysteme für beliebige Umgebungen verstanden werden, inklusive Verbesserung der Längsführung und Nutzbarmachung bei Abbiegevorgängen sowie bei optisch schwieriger zu erfassenden Fahrspurbegrenzungen. Im Ergebnis soll die Fahrzeugautomation auch bei Ausfall der GNSS-Navigation und in städtischen Bereichen verbessert werden. Hierbei konzentriert sich das DLR auf optisch anspruchsvolle Situationen, die von den industriellen Systemen noch nicht beherrscht werden. Im Ergebnis wird eine kontinuierliche Positions- und Lagebestimmung ohne Ausfälle und Positionssprünge angestrebt, die relativ zur Umgebung genau ist und damit ein sicheres Fahren im fließenden Verkehr ermöglicht, sowie unter Zuhilfenahme von Kartendaten absolut genau und damit für vernetztes Fahren geeignet ist. Im Realversuch werden Wechselwirkungen zwischen Navigation und Fahrzeugführung untersucht. Die Ergebnisse werden mit Referenzdaten validiert. Für die Entwicklung ist die Integration eigener Hardwarekomponenten erforderlich sowie die Zusammenführung der Sensorplattform des Partners iMAR mit den DLR-Versuchsanlagen vorgesehen. Die Projektergebnisse werden im wissenschaftlichen Umfeld veröffentlicht.

Teilprojekt Universität Göttingen: Lokalisierung und Mapping

Das Teilprojekt der Universität Göttingen (UGOE) konzentriert sich auf die Entwicklung neuer Methoden für die Datenfusion und Lokalisierung, insbesondere in Bezug auf die Integration von Karten. Ziel ist es, die Genauigkeit und Zuverlässigkeit der Lokalisierung in komplexen Umgebungen zu verbessern. Bei der Simultanen Lokalisierung und Kartierung (SLAM) wird untersucht, wie die Kombination von Sensordaten mit hochauflösenden Karten zuverlässigere

Lösungen erzielen kann. Zusätzlich sollen dynamische Objekte wie sich bewegende Verkehrsteilnehmer zur relativen Positionierung verwendet werden, um die Robustheit und Stetigkeit der relativen Lokalisierung zu erhöhen. Darüber hinaus werden insbesondere neue Methoden zur Lokalisierung basierend auf hochauflösenden Karten erforscht. Dazu gehören Landmarkenbasierte Ansätze, sowie neue Ansätze, die direkt mit Rohdaten und Kartendaten arbeiten. Dies umfasst zum Beispiel die Identifikation von Unsicherheiten, von Abhängigkeiten der Teilsysteme und von systematischen Fehlern der Karten. Hierbei werden auch neue Verfahren zur rekursiven nichtlinearen Zustandsschätzung untersucht, die weit über traditionelle Kalman-Filter-basierte Methoden hinausgehen.

2. Voraussetzungen, unter denen das Vorhaben durchgeführt wurde

Die Durchführung des Vorhabens wurde nach Bewilligung der Zuwendung zum 01.10.2022 begonnen, für eine Laufzeit von 36 Monaten. Details zur Zusammenarbeit zwischen den Projekt-partnern wurden in einem Kooperationsverbundvertrag geregelt. Die Bereitstellung von Personal und betrieblichen Ressourcen ist Grundvoraussetzung für die Durchführung. Hierzu, sowie zu den folgend genannten externen Abhängigkeiten wurde ein entsprechendes Risikomanagement betrieben.

Wesentlich ist die Verfügbarkeit und Funktionsfähigkeit der Versuchsträger sowie deren Betrieb im öffentlichen Raum. Das Vorhaben wurde unter der Annahme geplant, dass Versuchsfahrten inklusive Datenaufnahmen im öffentlichen Straßenverkehr stattfinden dürfen und dass das Aufstellen und der Betrieb von Referenzmesssystemen erlaubt ist bzw. genehmigt wird. Für Datenaufnahmen im öffentlichen Raum wurden partnerspezifische Datenschutzkonzepte unter Berücksichtigung der DSGVO bzw. des BDSG umgesetzt. Zur Einhaltung der Verkehrssicherheit wurden partnerspezifische Konzepte zum Fahrzeugbetrieb umgesetzt und geschultes Sicherheitsfahrpersonal eingesetzt.

Die Publikation der Forschungsergebnisse erfolgte nach Möglichkeit im Projektzeitraum und unter Verwendung der Projektmittel. Hier ist zu beachten, dass – abhängig von Publikationszeitraum und Erfolg des Peer-Review – auch außereuropäische Konferenzen in Betracht gezogen wurden, zu deren Reisen Mittel abseits der Zuwendung verwendet worden sind. Zudem sind einige der Ergebnisse im späten Projektverlauf entstanden. Diese werden erst nach Abschluss des Vorhabens publiziert und präsentiert.

3. Planung und Ablauf des Vorhabens

Das Vorhaben startete mit einem Kick-off am 22.11.2022 und endete mit einer Abschlussveranstaltung am 30.09.2025. Das Projekt wurde als Ganzes bearbeitet und war in neun inhaltliche Arbeitspakete (AP) sowie das AP 1 zur Projektkoordination unterteilt:

- AP 1: Projektkoordination
- AP 2: Konzeptionierung und Spezifikation

- AP 3: Konstruktion und Aufbau
- AP 4: Fahrversuche und Datengewinnung
- AP 5: Implementierung Relativortung
- AP 6: Implementierung Absolutortung und Sensorfusion
- AP 7: Referenzdatenoptimierung
- AP 8: Implementierung Fahrzeugführung und Manöverplanung
- AP 9: Gesamt-Systemintegration und Demonstration
- AP 10: Evaluation und Bewertung

Die einzelnen Arbeitspakete orientierten sich an zeitlich gestaffelten Meilensteinen, deren jeweiliger Erreichungszeitpunkt in der nachfolgenden Übersicht durch den zugehörigen Projektmonat kodiert und dokumentiert ist:

- MS 4: Definition der Demonstrationsziele,
- MS 18: Dachkonstruktion ist abgeschlossen,
- MS 30: Die Methoden zur Nutzung von hochgenauen Karten in Kombination mit Sensordaten sind erstellt,
- MS 36: Positionslösung ist im Echtzeit-Fahrversuch validiert und in einer Realumgebung demonstriert.

Abbildung 1 veranschaulicht die zeitliche Planung des Projekts sowie die Abhängigkeiten zwischen den einzelnen Arbeitspaketen und den zugehörigen Meilensteinen.

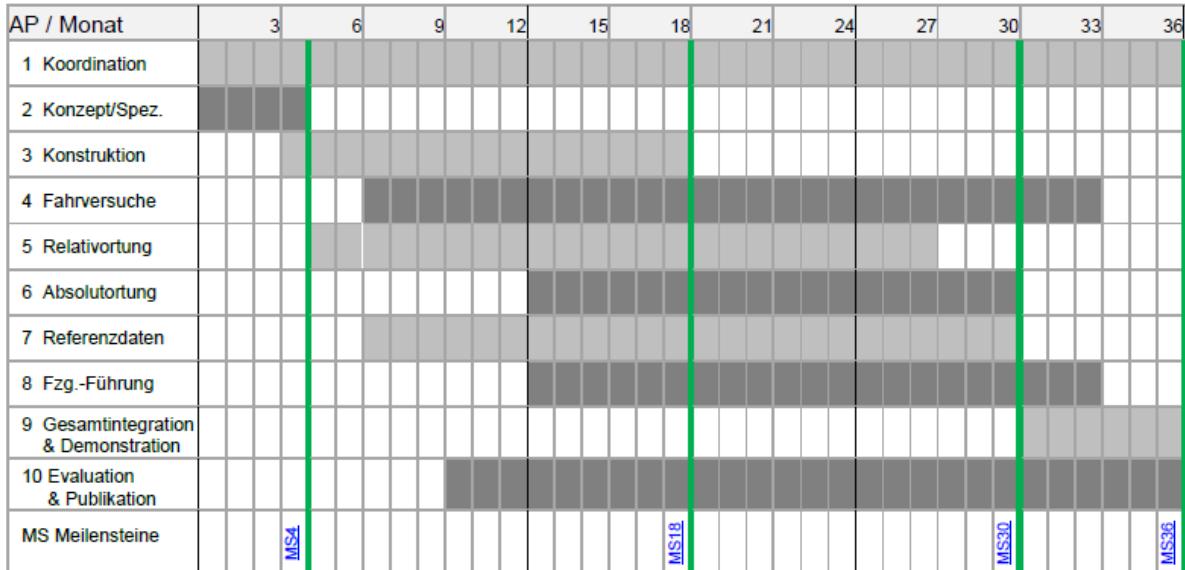


Abbildung 1: Gantt-Diagramm zum Projektablauf

4. Wissenschaftlicher und technischer Stand, an den angeknüpft wurde

Relevante Forschungsaktivitäten sind unter anderem im Kontext von *Simultaneous Localization and Mapping* (SLAM) [1] zu finden. SLAM beschäftigt sich mit der sensorbasierten Lokalisierung eines mobilen Roboters in einer unbekannten Umgebung, wobei gleichzeitig zur Lokalisierung auch eine Kartografierung der Umgebung durchgeführt wird. Ein grundsätzliches Problem sind dabei systematische Fehler, die zu einem „wegdriften“ der geschätzten Karte führen können. Durch Loop-Closures (d.h. Wiedererkennung einer bereits abgefahrenen Umgebung) und Berücksichtigung von GNSS kann dies teilweise behoben werden. Eine hochgenaue, spurrelleative Lokalisierung ist so jedoch nur schwierig zu erreichen. Die Verwendung von Karten zur Lokalisierung wird daher im Automotive-Bereich schon länger intensiv erforscht [2]. Beispielsweise betrachtet [3] ein Stereo-Kamera System sowie detaillierte Karteninformationen, um eine zentimetergenaue Lokalisierung zu erreichen. Weitere aktuelle Arbeiten basieren auf hochauflösenden Karten, wie zum Beispiel [4, 5, 6], oder verwenden direkt offline aufgenommene Kamera- oder Laserscannerdaten als Karten [7, 8]. Die Integration von low-resolution Kartendaten wurde in [9] erforscht. An diese Arbeit konnte mit den in den Abschnitten 1.2.4.2 und 1.2.4.3 beschriebenen Methoden angeknüpft werden. Auch an existierende Forschungsergebnisse bezüglich der zusätzlichen Integration von inertialer Messtechnik, sogenannter *Lidar Inertial Odometry* (LIO), wurde angeknüpft. Eine zentrale Methode ist hier LIO-SAM [10].

4.1. Angabe bekannter Konstruktionen, Verfahren und Schutzrechte, die für die Durchführung des Vorhabens benutzt wurden

Das Projekt knüpft an den technischen bzw. wissenschaftlichen Stand von Themen wie *visuelle Odometrie*, *Simultaneous Localization and Mapping*, *Automated Lane Keeping Systems*, *GNSS/INS-Positionierung*, *Koppelnavigation* usw. an; die in den eigenen Veröffentlichungen genannten Literaturangaben geben hier weitere Informationen. Sowohl die Gebietskörperschaften als auch die Hochschulen verfügten über keine eigenen Schutzrechte, die im vorliegenden Themenkomplex berücksichtigt werden mussten. Außerdem gab es keine Schutzrechte Dritter, die dem Vorhaben hätten entgegenstehen können. Bei der Entwicklung von Algorithmen griffen die Partner, wo möglich, auf Code-Bestandteile aus dem eigenen Haus oder auf frei verfügbaren Quellcode zurück.

4.2. Angabe der verwendeten Fachliteratur sowie der benutzten Informations- und Dokumentationsdienste

Die verwendete Fachliteratur, die in diesem Projekt zum Tragen kam, ist dem Literaturverzeichnis sowie den darin enthaltenen eigenen Veröffentlichungen zu entnehmen. Die Verfahren zum Abgleich mit georeferenzierten Karten verwendeten öffentlich zugängliche Daten von Open-StreetMap, sowie die eigens für das Projekt erstellten Kartendaten. Die im Projekt erstellten

Kartendaten [11, 12] wurden in der Mobilithek des BMV und dem OpenData-Portal der Stadt Braunschweig verzeichnet und sind unter dem Stichwort „Schwarzer Berg“ abrufbar.

5. Zusammenarbeit mit anderen Stellen

Für die OpenDRIVE-Kartierung in Braunschweig und der A 81 wurde die Firma 3D Mapping Solutions GmbH beauftragt. Maßgeblich für die Spezifizierung der zu kartierenden Bereiche war die potenzielle Weiternutzung der Braunschweiger Karte durch das DLR sowie die möglichst nachhaltige Verwertbarkeit. Die Arbeiten an LiDAR-gestützten Positionierungsverfahren erfolgten DLR-seitig in Synergie mit dem mFund-Projekt *European Digital Dynamic Mapping (EDDY)* (BMV, Fkz. 01F2208B) wobei dort der Schwerpunkt auf dem Thema der verteilten Kartenerstellung lag und nicht auf dem Thema Lokalisierung und Navigation.

Bei den Fahrversuchen im öffentlichen Raum in Braunschweig wurden Referenzmesssysteme aufgestellt und Luftbilder mit einer Drohne aufgenommen. Die hierzu erforderlichen Genehmigungen wurden von den zuständigen Behörden eingeholt.

II. Eingehende Darstellung

1. Verwendung der Zuwendung und erzieltes Ergebnis im Einzelnen, mit Gegenüberstellung der vorgegebenen Ziele

Der Abschnitt beschreibt zunächst die Arbeitspakete, nach denen das Projekt gegliedert wurde. Anschließend erfolgt eine ausführliche Beschreibung der Beiträge der einzelnen Partner. Abschließend werden die Ergebnisse zusammengefasst und den vorgegebenen Zielen gegenübergestellt.

1.1. Arbeitspakete

AP 1. Projektkoordination

Das übergeordnete Arbeitspaket 1 umfasst die zentralen Steuerungs- und Koordinationsaufgaben, die beim Konsortialführer iMAR Navigation GmbH für das Gesamtprojekt anfallen. Dazu zählen insbesondere administrative Tätigkeiten, die übergeordnete Abstimmung und Kommunikation mit den Projektpartnern, die Ausarbeitung und Vereinbarung einer Kooperationsvereinbarung sowie die Organisation und Durchführung von Projekttreffen. Darüber hinaus beinhaltet dieses Arbeitspaket die Koordination des Berichtswesens, die Überwachung der Meilensteinerreichung sowie die Sicherstellung der fristgerechten und inhaltlich vollständigen Umsetzung aller im Projektplan definierten Aufgaben. Im Rahmen dieses Arbeitspaketes sind ausschließlich Tätigkeiten vorgesehen, die dem Konsortialführer zugeordnet sind.

Die Koordination des Projekts wurde über alle sechs Projektinkremente (Berichtszeiträume) durchgeführt. Dabei wurden wöchentliche Meetings abgehalten, um eine flüssige Koordination der Partner zu gewährleisten. Diese Meetings und auch wichtige Erkenntnisse wurden im Weiteren im Gitlab der Universität Göttingen dokumentiert. Zu den einzelnen Projektinkrementen wurden Projekttreffen bei den Standorten der Partner Valeo, iMAR und DLR organisiert. Des Weiteren wurde der Kaufprozess der projektrelevanten Kartendaten geplant und durchgeführt. Für jedes Inkrement wurde auch ein partnerspezifischer Bericht ausgearbeitet.

Nach Projektinkrementen aufgeschlüsselt wurden folgende Planungsprozesse und Treffen durchgeführt. Abbildung 2 zeigt diese in kompakter Form.

1. Im ersten Projektinkrement wurde das Projekt administrativ aufgesetzt und das Kick-off durchgeführt. Das Kick-off Meeting fand in Braunschweig (DLR) am 22.11.2022 statt und behandelte sowohl administrative wie auch technische Aspekte und gab einen Überblick über die projektspezifische Ausstattung des DLR.
2. Ferner wurde das Folge-Meeting beim Projektpartner Valeo in Kronach im Januar 2023 geplant. Dieses wurde am 15.01.2023 von Valeo in Kronach ausgerichtet, und der weitere Projektplan sowie die Folgestrategie und Aufgaben der Partner und die Anwendungsfälle im Projekt wurden konkretisiert.

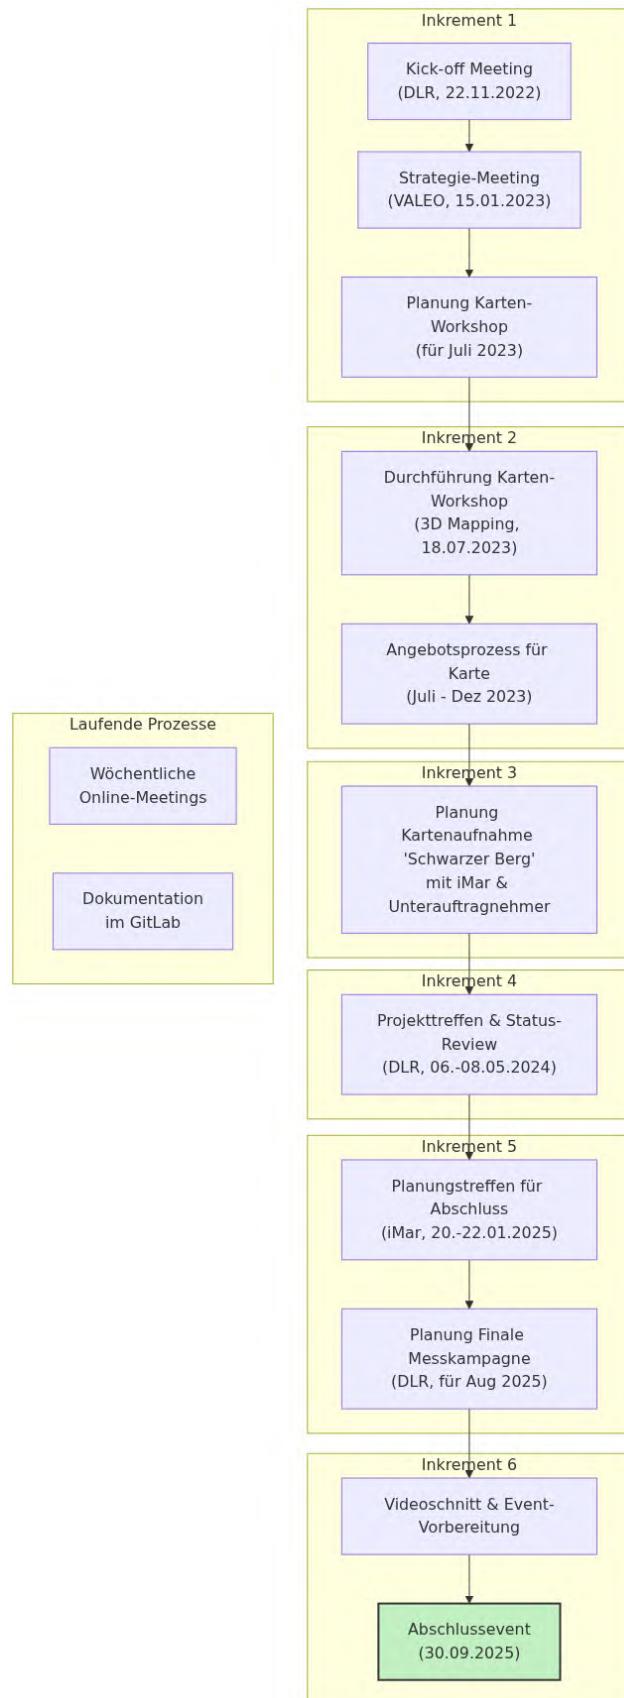


Abbildung 2: Der zeitliche Verlauf des Projekts sowie die parallel verlaufenden Aufgaben.

3. Im weiteren Verlauf wurde ein Workshop bei dem Unterauftragnehmer 3D Mapping Solutions in Holzkirchen auf den 18.07.2023 geplant. Bei diesem werden die Erstellung und der Kauf projektrelevanter hochgenauer Karten besprochen.
4. Im zweiten Projektinkrement wurde der zuvor geplante Workshop bei dem Unterauftragnehmer 3D Mapping Solutions in Holzkirchen durchgeführt. Infolgedessen wurde die interne Kaufbeauftragung der für das Projekt notwendigen Karte in mehreren Sessions mit 3D Mapping Solutions geprüft, und ein finales Angebot wurde erstellt. Dieser Prozess umfasste den Zeitraum vom 18.07.2023 bis zum 01.12.2023. Nach Prüfung erfolgte daraufhin die Beauftragung.
5. Die Planung der Projekttreffen im Folgejahr wurde begonnen. Dabei wurde ein besonderes Augenmerk auf die Kartenaufnahme des Stadtquartiers am Schwarzen Berg in Braunschweig gelegt, die mit dem Unterauftragnehmer geschehen soll, und bei welchem Referenzdaten des Partners iMAR aufgezeichnet werden sollten.
6. In dem dritten Projektinkrement wurde das zuvor geplante Projekttreffen bei dem Partner DLR in Braunschweig vom 06.05.2024 bis zum 08.05.2024 durchgeführt. Dabei wurde der Stand der Arbeiten festgestellt, und auch mit Beteiligung des Projektträgers erörtert und die Planung der Aktivitäten des Inkrements wurden fortgeführt.
7. Im vierten Projektinkrement wurde ein Projekttreffen bei dem Projektpartner iMAR in St. Ingbert (20.-22.01.2025) durchgeführt. Es diente dem Austausch zum aktuellen Projektstand und der Planung der nächsten Schritte. Unter Beteiligung des Projektträgers wurden der Projektfortschritt bewertet und die Planung der finalen Messkampagne sowie des Projektabschlusses konkretisiert.
8. Im fünften Projektinkrement wurde eine Projekttreffen bei dem Projektpartner DLR in Braunschweig (18.-21.08.2025) geplant. Dieses Treffen diente dem Austausch zum aktuellen Projektstand und einer finalen Messkampagne mit Videoaufnahmen sowie der Konkretisierung des Projektabschlusses zum 30.09.2025.
9. Im finalen Projektinkrement wurde der Videoschnitt sowie die Planung, Vorbereitung und Durchführung des Abschlussevents am 30.09.2025 durchgeführt. Dies wurde weiter mit wöchentlichen Meetings und direkter Zusammenarbeit, im speziellen mit iMAR für den Videoschnitt, ausgearbeitet.

AP 2. Konzeptionierung und Spezifikation

Das Arbeitspaket 2 umfasst die weitere Evaluation des Standes der Technik, die gemeinsame Anforderungsanalyse, die Spezifikation von relevanten Szenarien und die konkrete Spezifikation des im Projekt zu entwickelnden Systems inklusive der Demonstrationsziele. In diesem Arbeitspaket wurde im ersten Projektinkrement eine eingehende Literaturrecherche durch alle Partner durchgeführt.

Spezifikation von Szenarien und konkreter Anwendungsfälle für eine Demonstration, daraus Ableitung von konkreten Testfällen und Festlegung der Demonstrationsziele

Die Szenarien und konkreten Anwendungsfälle sowie die Demonstrationsziele aller Partner wurden in einem Workshop am 15.01.2023 in Kronach erstellt. Die identifizierten Szenarien und die Zuordnung der Partner sind in Tabelle 1 dargestellt. Die auf diesen Szenarien basierenden Usecases und Anwendungen sind in den folgenden Punkten aufgelistet:

- Fahrt durch Tunnel
- Fahrt durch Baustelle (Testplatz)
- Kartengestütztes Umfeldmodell
- Verlassen der Karte
- Autonomes Fahren auf Forschungskreuzung.

Die Bearbeitung der Anwendungsfälle und Usecases wird in den partnerspezifischen Bereichen beschrieben.

Anwendungsfälle	Partner
GPS Ausfall, z.B. Urban Canyon / Tunnel	iMAR/DLR
GPS Rauschen / Drift (Waldtunnel)	iMAR/DLR
Veränderung der Karte (z.B. Baustelle auf Teststrecke)	Alle Partner
Fehlende Spurmarkierungen / Implizite Spurmarkierung	DLR
Umfeldmodell mit Karte Fusioniert	Valeo
Poseschätzung relativ zur Karte	Valeo
Lokalisierung gegen Landmarken	DLR/iMAR
Lokalisierung gegen „Punktwolkenkarten“	DLR/iMAR
Punktwolken Registrierung	Uni Göttingen
Robustheit gegen Sensor-Ausfälle in Lokalisierung	Uni Göttingen
Verlassen der Lidar Karte	DLR/iMAR
Robustheit gegen systematische/korrelierte Karten-Fehler	Valeo/Uni Göttingen
Statische Sensorik als Referenzsystem für Perzeption	DLR
Abschätzen eigener Unsicherheit der Position	Alle Partner

Tabelle 1: Anwendungsfälle, die die Partner identifizierten.

AP 3. Konstruktion und Aufbau

Im Rahmen dieses Arbeitspakets wurde eine Lokalisierungsplattform zur Aufnahme eines modularen Sensorsaufbaus realisiert, bestehend aus einem LiDAR- und Kamerasystem, einem Inertialnavigationssystem (INS), GNSS-Empfängern sowie einer leistungsfähigen Datenerfassungs- und Prozessierungseinheit. Bei der Konzeption und Umsetzung der Plattform waren zahlreiche technische Randbedingungen zu berücksichtigen, die im Folgenden zusammengefasst werden:

- Mechanische Konzeption: Entwicklung einer leichten, witterfesten und zugleich verwindungssteifen Struktur zur Gewährleistung einer präzisen extrinsischen Sensorkalibrierung. Der Aufbau wurde so gestaltet, dass er flexibel und mit geringem Aufwand auf verschiedenen Trägerfahrzeugen montiert werden kann.

- Systemintegration: Minimierung der erforderlichen Kabelverbindungen zu den einzelnen Komponenten auf das technisch notwendige Minimum (z. B. Datensignal, Spannungsversorgung) unter gleichzeitiger Berücksichtigung elektromagnetischer Verträglichkeit (EMV) bei der hochfrequenten Signalverarbeitung.
- Signal- und Zeitmanagement: Auslegung der Hardwarearchitektur auf eine präzise Datenzeitstempelung sowie eine latenzarme Sensortriggerung bei gleichzeitig hoher Datenbandbreite.
- Sensorik: Integration eines leistungsfähigen LiDAR-Systems und Erweiterbarkeit um Kameras, um sowohl dichte 3D-Punktwolken als auch visuelle Referenzdaten erfassen zu können.
- Recheneinheit: Auswahl und Integration einer Embedded-Recheneinheit mit ausreichender Rechenkapazität bei gleichzeitig geringer Energieaufnahme, um auch einen autarken Batteriebetrieb und spontane Einsätze auf Testfahrzeugen zu ermöglichen.

Die im Anschluss erfolgten Arbeiten umfassten den Aufbau, die elektrische Inbetriebnahme sowie die Validierung der Hardwareplattform. Ergänzend wurde die erforderliche Embedded-Software entwickelt, einschließlich der Implementierung von Gerätetreibern, der Einrichtung der Prüfumgebung und der Durchführung von Funktionstests.

Die Partner DLR und Valeo haben weitgehend Umbauten an ihren Versuchsträgern durchgeführt während iMAR einen vollständig neuen Aufbau entworfen und umgesetzt hat. Die Details sind in den entsprechenden partnerspezifischen Bereichen zu finden.

AP 4. Fahrversuche und Datengewinnung

Die Aufgaben in diesem AP umfassen die entwicklungsbegleitenden Versuche zur Gewinnung von Daten, die für die Implementierung der Software und die Evaluation benötigt werden. DLR, iMAR und Valeo stellen Fahrversuchsträger, dazu stellt das DLR Infrastruktursensorik. Hinzu kommen die zur Projektlaufzeit durch iMAR entwickelte Dachkonstruktion zur Fahrzeugdatenaufnahme, sowie die vom DLR entwickelte mobile Infrastruktursensorik zur Referenzdatenaufnahme. Die Versuche finden entwicklungsbegleitend sowie nach Abschluss der Implementierung statt. Im Projekt wurden neben den entwicklungsbegleitenden Versuchsfahrten, die über den gesamten Projektverlauf hinweg stattfanden, folgende großangelegten Versuchskampagnen durchgeführt:

Stadtgebiet Braunschweig

Im Februar 2024 erfolgten die Vermessungsfahrten durch die 3D Mapping GmbH, hierbei wurde die Kartierung durch eigene Aufnahmen des DLR begleitet. Dadurch gibt es Messdaten zum gleichen Zeitpunkt wie die Referenzkartenaufnahme. Mehrere weitere Messkamagnen erfolgten zwischen April 2024 und August 2025. Kern der Arbeiten waren Aufnahmen von Fahrzeug- und Infrastrukturdaten unter unterschiedlichen Bedingungen (siehe Abbildung 3). So gab es beispielsweise in einer Messkampagne eine größer angelegte Baustelle.



Abbildung 3: Fahrversuche in Braunschweig. Fahrzeuge der Projektpartner (links), Referenzmessungen mit Infrastruktur und Drohne (rechts).

Raum Saarbrücken

Von Mai bis September 2025 erfolgte die Erstellung des zur Veröffentlichung bestimmten Odyssey-Datensatzes, der über 33 Sequenzen im urbanen und suburbanen im Landkreis Saarbrücken umfasst. Diese ergänzenden Aufnahmen wurden auf Grundlage der im Projekt identifizierten Bedarfslücken ausgewählt und gezielt erhoben, um die vorhandenen Datensätze inhaltlich zu vervollständigen und eine breitere Abdeckung relevanter Verkehrsszenarien zu gewährleisten, siehe Abbildung 4. Die Daten stehen online zur Verfügung¹. Die vollständige wissenschaftliche Publikation des Datensatzes befindet sich zu Berichtsabgabe bereits im finalen Prozess.

Autobahn A 81

Im Verlauf des Projekts wurden kontinuierlich Daten mit den Versuchsfahrzeugen aufgezeichnet, und die Algorithmen wurden mit diesen getestet. Dabei wurden Aufnahmen innerhalb der Karten der A81 von Bietigheim bis zum Kreuz Leonberg fokussiert. Speziell der Bereich des Engelbergtunnels war hierbei von Interesse, da dieser sich in der Zeit des Projekts in einem kontinuierlichen Umbau befand. Abbildung 5 zeigt die Aufnahme der Referenzkamera einer Testfahrt durch den sich im Umbau befindlichen Engelbergtunnel.

Teile dieser Aufnahmen wurden auch für das Projektvideo verwendet und können in diesem eingesehen werden. Speziell ist dabei eine Fahrt durch den Engelbergtunnel mit der korrespondierenden Karte sowie den Sensorinformationen des Fahrzeugs zu sehen.

AP 5. Implementierung Relativortung

Die Zielsetzung des Arbeitspakets 5 bestand in der Entwicklung und Validierung von Verfahren zur Relativortung, die ausschließlich auf der Auswertung von LiDAR und inertialen Sensordaten basieren. Dabei sollten relative Bewegungsänderungen unabhängig von globalen Referenzen wie GNSS oder digitaler Karte präzise, driftarm und robust bestimmt werden. Dies bildet eine zentrale Grundlage für die spätere absolute Lokalisierung sowie für die Nutzung der Sensorplattform unter GNSS-denied-Bedingungen.

¹<https://odyssey.uni-goettingen.de/>

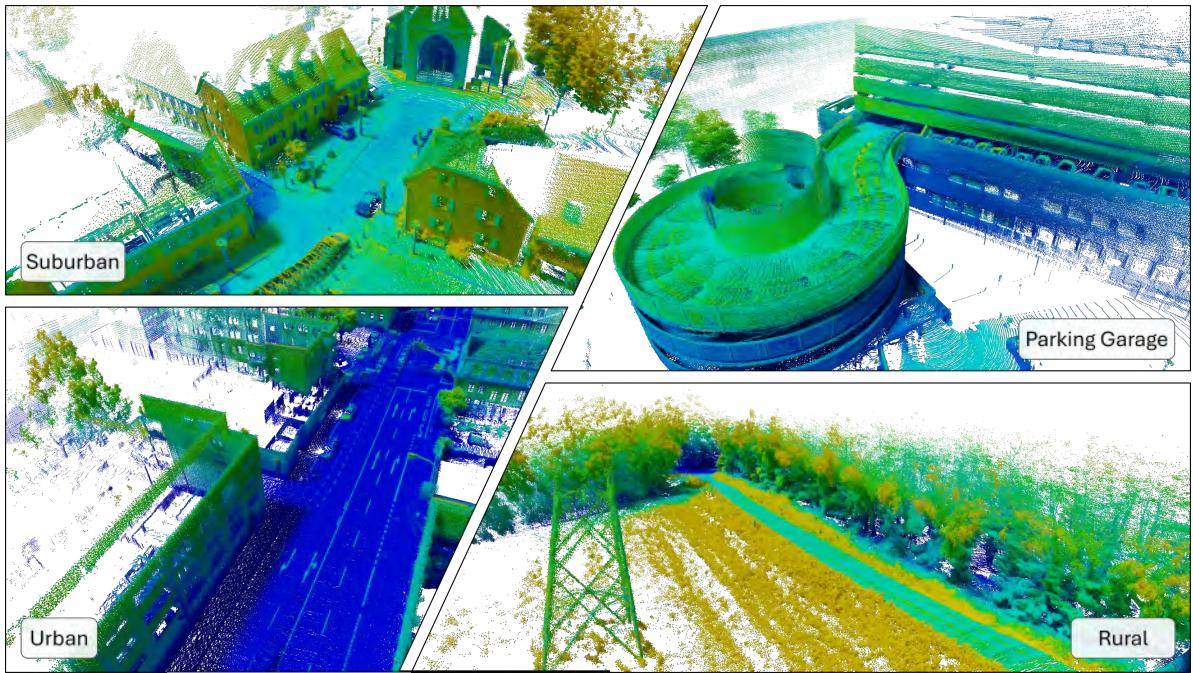


Abbildung 4: Übersicht Odyssey-Datensatz: Typische urbane, suburbane und ländliche Umgebungen sowie langandauernde GNSS-denied-Situationen, wie beispielsweise Parkhäuser und Tunnel.



Abbildung 5: Auszug der Referenzkamera einer Messfahrt im Engelbergtunnel.

Zur Erreichung dieser Ziele wurde zunächst ein LiDAR-basiertes Odometrieverfahren etabliert, das Relativbewegungen zwischen sukzessiven Punktfolgen durch Scan-Matching bestimmt. Bestehende SLAM-/LiDAR-Odometrie-Frameworks wurden hierzu analysiert, auf projektspezifische Anforderungen angepasst und um Mechanismen zur Erhöhung der Robustheit erweitert. Zur Stabilisierung der relativen Bewegungsschätzung wurde die Odometrie eng an die iner-

tiale Bewegungsvorhersage gekoppelt. Dadurch konnte die Konsistenz auch in Szenarien mit geringer geometrischer Struktur oder wiederkehrenden Umgebungsmerkmalen deutlich erhöht werden. Eine kontextbasierte Behandlung nichtbeobachtbarer Zustände sowie ein erweitertes Outlier-Management reduzierten Fehlanpassungen im Scan-Matching-Prozess und verhinderten das Abdriften der Lösung in lokal suboptimale Minima.

Die entwickelten Verfahren wurden anschließend anhand der im Projekt aufgezeichneten Datensätze evaluiert. Diese umfassten vielfältige Verkehrsszenarien wie Wohngebiete, innerstädtische Abschnitte, Parkhäuser, Tunnel sowie Strecken mit bewegten Objekten und engen räumlichen Strukturen. Die Ergebnisse zeigen, dass durch die Kombination aus LiDAR-Odometrie und inertialer Stützung eine deutliche Driftreduktion gegenüber reiner Odometrie erzielt werden konnte. Über längere Trajektorien in GNSS-freien Abschnitten wurden relative Positionsänderungen stabil im Dezimeterbereich rekonstruiert, ohne dass signifikante Fehlaufschwingungen oder Divergenzen auftraten.

Die im Arbeitspaket entwickelten und verifizierten Verfahren erfüllen damit die Zielsetzung des AP 5 vollständig. Sie stellen eine wesentliche Basis für die nachgelagerten Arbeitspakete zur absoluten Lokalisierung, zur Sensordatenfusion sowie für die Bewertung der Gesamtperformanz der im Projekt entwickelten Lokalisierungslösungen dar.

AP 6. Implementierung Absolutortung und Sensorfusion

Ziel dieses Arbeitspakets ist die Kombination der hochauflösenden Karte mit der fahrzeugeigenen Sensorik, insbesondere GNSS/IMU, sowie Kamera- und LiDAR-Sensoren. Diese Kombination hat zwei Aspekte: Zum einen lässt sich über den Abgleich zwischen Sensordaten und Landmarken in der hochgenauen Karte eine hochgenaue absolute Positionierung erzielen. Zum anderen kann eine absolute Positionierung dazu verwendet werden, die Informationen aus der hochgenauen Karte mit den Daten der fahrzeugeigenen Sensoren, insbesondere Kamera und LiDAR, zu einem konsistenten Umfeldmodell zu fusionieren. Da beide Aspekte stark miteinander verbunden sind, werden im AP 6 beide gemeinsam behandelt, um Synergien zu maximieren. Die Aufgaben umfassen hier:

- Analyse zu systematischen Fehlermoden in Sensor- und Kartendaten und Entwicklung KI-basierter Verfahren zur Bewertung und Auswahl (sog. Outlier-Detection) der Sensor- und Kartendaten, u.a. im Hinblick auf eine Rekonfigurierbarkeit (z.B. bei systematischen Fehlern oder temporär verminderter Datenqualität).
- Entwicklung von Methoden zur Fusion von fahrzeuglokalen Sensordaten (intrinsisch, z.B. IMU/Odometer und extrinsisch, d.h. LiDAR, Kamera, GNSS) mit Informationen aus hochgenauen Karten zur genauen Positionierung in globalen Weltkoordinaten. Es wird auf den zu Beginn von AP 5 erarbeiteten Ergebnissen der relativen Ortung aufgesetzt. Bei der Absolutortung steht der globale Kontext im Mittelpunkt, d.h. das absolute Heading, die absolute Fahrzeuggeschwindigkeit und die absolute Position usw. Hiermit sollen Methoden der Sensorfehlerschätzung und -korrektur implementiert und erprobt werden. Mit dieser

Komponente zusammen mit der Relativortung erhält man am Ende die Lokalisierung mit der benötigten Robustheit inklusive einem Set von Zielfunktionen:

- Aufbau einer Visualisierung von hochgenauen Karten und Sensordaten in 3D (OpenGL) sowie Aufbau von Entwicklungswerkzeugen,
- Entwicklung einer kartengestützte Bodenerkennung in Punktwolkensensoren, insbesondere LiDAR,
- Aufbau eines Modells zur kartengestützten Definition eines dynamischen Region of Interest,
- Aufbau eines Modells zum kartengestützten Clustering von Detektionen aus Punktwolken-Sensoren
- Kartengestützte Auswahl an Bewegungsmodellen sowie multimodale Prädiktion von Objekten anhand von Spurinformationen,
- Fusion von Sensor- und Spurinformation einer hochauflösenden Karte zur redundanten Spurerkennung,
- Echtzeitoptimierung der Algorithmen.

AP 7. Referenzdatenoptimierung

Dieses AP umfasst die Erfassung von Referenzdaten zur Bewertung der in AP 5/6 implementierten Verfahren. Hierzu werden die mit DLR-Infrastrukturanlagen gewonnenen Referenzdaten hinsichtlich Detektionsqualität sowie zeitlicher und räumlicher Genauigkeit der Referenzobjektdaten optimiert. Zudem sollen infrastrukturseitig vorhandene Corner Cases bei der Detektion behandelt werden. Damit werden Ground-Truth-Daten zum Testen und Validieren der aus der Ego-Perspektive geschätzten absoluten Ego-Pose bereitgestellt.

AP 8. Implementierung Fahrzeugführung und Manöverplanung

Ziel dieses AP ist die Entwicklung von Lösungen für die genaue Fahrzeugführung und Manöverplanung unter Berücksichtigung von Positionsunsicherheiten. Hintergrund ist die sich verändernde Qualität von Positionsdaten sowie Positionssprünge, die durch intelligente Anpassung der Fahrzeugführung kompensiert werden sollen.

Die Umsetzung im Projekt ist stark abhängig vom Stand der Implementierung einer echtzeitfähigen Positionierungslösung und dessen Integration in eines der Forschungsfahrzeuge. Bezogen auf die verschiedenen im Projekt umgesetzten Ansätze konnte mit dem ROS-HDL-Package [13], basierend auf vorher automatisiert eingemessenen Karten, der höchste Reifegrad erzielt werden. Die Integration in das DLR-Fahrzeugsystem ergibt eine kombinierte GNSS/LiDAR/INS-Lösung mit Ausgabedaten, die kompatibel zu z.B. NovAtel-typischen INS/PVA-Zustandsvektordaten sind. Bei einer georeferenzierten Karte zeigt sich eine Positionierung besser als GNSS [14], wobei durch die Kombination von LiDAR-Punktwolkenregistrierung, GNSS und INS Fehler bzw. Lücken in der Karte zu einem gewissen Grad tolerierbar sind. Mit der Schnittstelle zum DLR-Automationsframework *ADORE* [15] wurde schließlich die Evaluation des Positionierungsverfah-

rens im automatisierten Fahrbetrieb ermöglicht. Fahrversuche im automatisierten Betrieb waren insgesamt erfolgreich, mit einem als stabil wahrgenommenen Fahrverhalten. In aktuellen Forschungsarbeiten des DLR zur Manöver- und Trajektorienplanung [16] sowie Regelung [17] ist die Berücksichtigung und insbesondere Prädiktion des Verkehrsgeschehens das vorherrschende Thema im Hinblick auf ein vorausschauendes und sicheres Fahren.

AP 9. Gesamt-Systemintegration und Demonstration

In diesem Arbeitspaket erfolgte die Gesamtsystemintegration der im Projekt entwickelten Komponenten auf die jeweilige Zielhardware sowie deren Einbindung in die Versuchsträger. Darüber hinaus wurden die entwickelten Lösungen demonstriert und validiert. Die Projektpartner setzten hierzu jeweils unterschiedliche Versuchsträger-Hardware ein, wobei funktional zusammenhängende Komponenten innerhalb eines gemeinsamen Versuchsträgers integriert wurden. Die spezifischen Integrations- und Demonstrationsaktivitäten werden in den jeweiligen Partnerabschnitten beschrieben.

Im Rahmen der abschließenden Messkampagne am Standort „Schwarzer Berg“ wurden Teillösungen der einzelnen Partner zusammengeführt. Dabei wurde unter anderem die von iMAR entwickelte RLG-basierte Ground-Truth-Lösung mit der Versuchsanlage des DLR gekoppelt. Das Zusammenwirken der Systeme sowie die Durchführung der Versuche wurden videografisch dokumentiert.²

AP 10. Evaluation und Publikation

Dieses projektbegleitende Arbeitspaket umfasst alle Arbeiten zur Evaluation von Zwischen- und Endergebnissen sowie die Auswertung und Bewertung im Hinblick auf die zu erreichenden Projektziele und die Dokumentation der Projektergebnisse. Die Arbeiten sind in den Abschnitten zu den jeweiligen Fachthemen bereits dokumentiert. Eine Gegenüberstellung zu den vorgegebenen Zielen ist unter Abschnitt 1.3, die Publikationen des Projekts sind im Abschnitt 6 bzw. im Literaturverzeichnis zu finden.

1.2. Beiträge der einzelnen Partner

1.2.1. iMAR Navigation GmbH

1.2.1.1. Modulare Sensorplattform

Im Rahmen des Verbundvorhabens wurde eine modulare Sensorplattform entwickelt, welche die kombinierte Erfassung, Synchronisation und Fusion unterschiedlicher Sensordaten für Untersuchungen zur optischen Lokalisierung ermöglicht, siehe Abbildung 6. Die Plattform basiert auf einem flexiblen, fahrzeugunabhängigen Aufbaukonzept, das den Einsatz verschiedener Sensoren – darunter LiDAR-, Kamera- und inertiale Systeme – gestattet. Kernkomponenten bilden ein Ouster-LiDAR mit 128 Kanälen sowie inertiale Messeinheiten der iNAT-Serie (M200/M300) von

²<https://youtu.be/ZiVMJZsKAmA>

iMAR Navigation. Durch die kompakte Bauweise der Dach- bzw. Messplattform ist eine einfache Montage an unterschiedlichen Fahrzeugen gewährleistet.

Zur Gewährleistung einer hohen Datenintegrität wurde eine umfassende Software-Toolchain implementiert, welche die robuste Erfassung, zeitliche und räumliche Synchronisation sowie die redundante Speicherung und Verteilung der Sensordaten innerhalb des Konsortiums sicherstellt. Die Zeitsynchronisation erfolgt dabei mit einer Genauigkeit im Nanosekundenbereich und greift bis auf die Rotorebene des LiDAR-Systems durch. In Phasen ohne GNSS-Verfügbarkeit wird die Zeitbasis durch ein FPGA-basiertes Zeitmanagement innerhalb der iNAT-M300-Architektur aufrechterhalten, wodurch eine konsistente und hochpräzise Zeitreferenz auch unter GNSS-denied-Bedingungen gewährleistet bleibt.

Der Messaufbau wurde ferner um eine hochgenaue Ground-Truth-Referenz auf Basis eines Ringlaser-INS erweitert, um die Positions- und Orientierungsgenauigkeit der entwickelten Lokalisierungsverfahren quantitativ bewerten zu können. Auf dieser Grundlage können die durch die Plattform erzeugten Daten zur Validierung, Optimierung und Vergleichbarkeit der im Projekt erarbeiteten SLAM- und Sensordatenfusionsalgorithmen herangezogen werden.

Die Sensorplattform erlaubt die Erfassung umfangreicher, qualitativ hochwertiger Datensätze auch in komplexen Szenarien, insbesondere unter GNSS-denied-Bedingungen oder in strukturell herausfordernden Umgebungen wie Tunnel oder urbane Bereiche. Darüber hinaus wurde die Plattform erfolgreich in unterschiedlichen Anwendungsumfeldern – u.a. im Bahnbereich – eingesetzt und hat dort die Erzeugung georeferenzierter Punktwolkenkarten mit hoher Präzision ermöglicht.

Durch ihre modulare und offene Architektur, die Nutzung standardisierter Kommunikationsschnittstellen (z. B. ROS 2-basierte iXCOM-Integration) sowie die hohe zeitliche Kohärenz der Sensordaten stellt die entwickelte Plattform eine leistungsfähige Grundlage für zukünftige Entwicklungen, Evaluierungen und den Transfer der im Projekt gewonnenen Erkenntnisse in praktische Anwendungen dar.



Abbildung 6: Im Projekt aufgebaute Sensorplattform, inkl Referenzlokalisierung zur Datenaquisition und autarken Navigation mit Hochleistungs-Fahrzeugrechner

1.2.1.2. Transfer von Forschungsergebnissen aus dem Bereich LiDAR-SLAM und LiDAR-Odometrie in anwendungsreife Systemlösungen

Der Transfer der im Projekt erarbeiteten Forschungsergebnisse aus dem Bereich LiDAR-SLAM und LiDAR-Odometrie in praxistaugliche Systemlösungen bildete einen zentralen Schwerpunkt der Arbeiten. Ziel war es, wissenschaftlich entwickelte Algorithmen aus der Forschung in robuste, echtzeitfähige und wartbare Softwarekomponenten zu überführen, die in industriellen Anwendungen unmittelbar eingesetzt werden können.

Ausgangspunkt bildeten Open-Source-Frameworks aus der wissenschaftlichen Community, deren algorithmische Ansätze im Projekt hinsichtlich Stabilität, Echtzeitfähigkeit und Ressourcenverbrauch umfassend analysiert, angepasst und weiterentwickelt wurden. Zentrale Schwerpunkte lagen in der Optimierung der Front-End-Verarbeitung (Feature-Extraktion, Motion-Compensation) sowie der Back-End-Optimierung [10, 18]. Ergänzend wurde die Sensordatenfusion um inertiale und – in späteren Entwicklungsphasen zur Georeferenzierung auch GNSS-Informationen erweitert, um eine robuste Lokalisierung auch unter GNSS-denied-Bedingungen sicherzustellen. Die implementierte Softwarearchitektur ist modular aufgebaut, vollständig ROS-2-kompatibel und für den Betrieb auf der iMAR-Sensorplattform optimiert.

Durch gezieltes Profiling und die Implementierung von Parallelisierungs- und Caching-Mechanismen konnte die Verarbeitungslatenz signifikant reduziert werden. Damit wurde die Grundlage geschaffen, die Verfahren auch in ressourcenlimitierten Embedded-Umgebungen einzusetzen.

Die entwickelten Softwarekomponenten wurden in eine CI/CD-Umgebung integriert und durch automatisierte Regressionstests validiert, wodurch eine nachhaltige Qualitätssicherung gewährleistet ist. Auf Basis dieser Infrastruktur ist eine reproduzierbare Bewertung der Algorithmik unter realen Einsatzbedingungen möglich. Die Überführung der LiDAR-SLAM- und Odometrie-Verfahren in eine industriell nutzbare Systemumgebung ermöglicht die unmittelbare Anwendung der erzielten Forschungsergebnisse in Bereichen wie dem szenarienbasierten Testen automatisierter Fahrzeuge, der präzisen Navigation unter GNSS-Störungen sowie der infrastrukturellen Instandhaltungsplanung. Damit leistet das Vorhaben einen wesentlichen Beitrag zum Technologietransfer zwischen Forschung und industrieller Umsetzung im Bereich sicherer, autonomer Mobilitätssysteme.

1.2.1.3. Verifikation von Lokalisierungslösungen im GNSS-denied-Umfeld

Für die Bewertung der im Projekt entwickelten Lokalisierungsverfahren wurde ein methodischer Ansatz erarbeitet, der eine kontinuierliche, GNSS-unabhängige Referenztrajektorie bereitstellt. Grundlage ist ein zweistufiges Verfahren aus kartengestützter Umfelderfassung und anschließender LiDAR/INS-basierter Relokalisation. Zunächst wird das Testgebiet vollständig vermessen und als georeferenzierte Punktwolkenkarte modelliert. Diese dient im Verifikationsschritt als globales Referenzmodell. Die spätere Lokalisierung erfolgt durch kontinuierliches Abgleichen der aktuellen LiDAR-Daten mit dieser Karte, stabilisiert durch die inertiale Bewegungsschätzung. Dadurch werden Position und Orientierung auch ohne GNSS konsistent rekonstruiert.

Zur eigentlichen Verifikation wird die Trajektorie des Prüfsystems mit einer LiDAR/INS-Referenztrajektorie verglichen, die unabhängig von GNSS generiert wird. Durch integrierte

Konsistenzprüfungen und Outlier-Detection-Mechanismen werden Fehlzuordnungen im Scan-Matching sowie nichtbeobachtbare Zustände isoliert, sodass Drift und Artefakte gezielt unterdrückt werden. Die resultierende Referenz steht mit einer zeitlichen Auflösung von bis zu 400 Hz zur Verfügung und erlaubt eine kontinuierliche, punktweise Bewertung der Navigationsleistung über die gesamte Strecke.

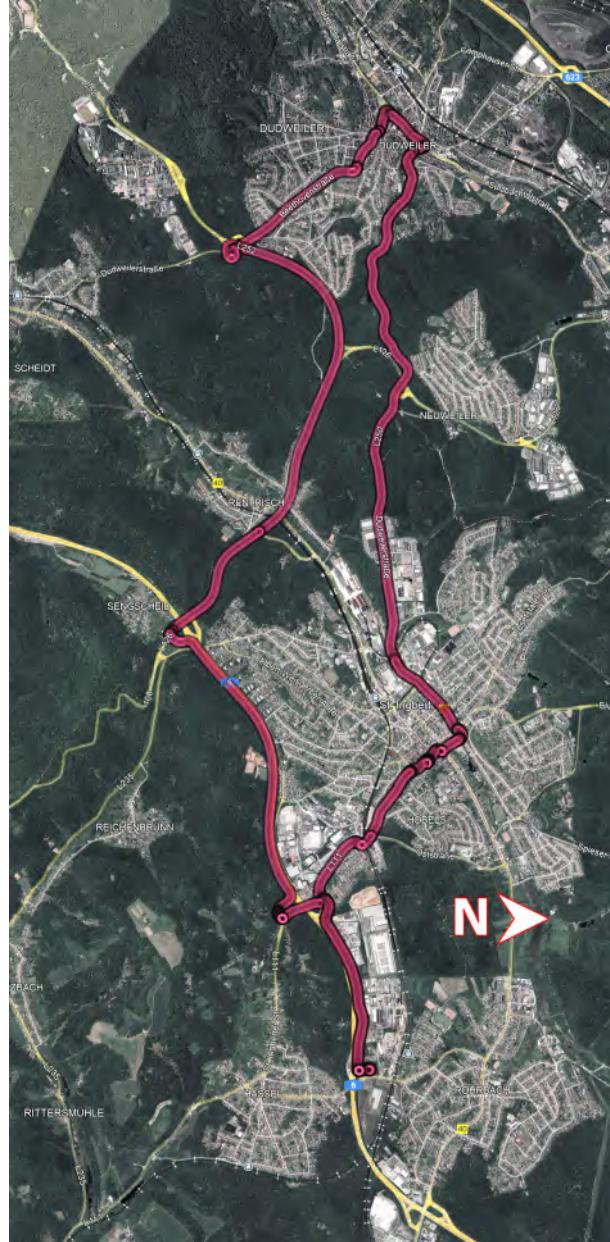


Abbildung 7: Satellitenansicht der heterogenen Teststrecke, die zur Bewertung der Methode verwendet wurde. Die Strecke begann auf dem Firmengelände der iMAR Navigation GmbH (St. Ingbert, Deutschland) und führte zunächst westwärts durch ein Wohngebiet. Nach dem Durchfahren eines ländlichen Abschnitts im Westen verlief der Rückweg über eine südlich gelegene Autobahn in östlicher Richtung.

Die durchgeführten Versuche, hier exemplarisch anhand einer heterogenen Trajektorie über Stadt und Land dargestellt (s. Abb. 7f.), zeigen, dass die erzielte Referenztrajektorie eine horizon-

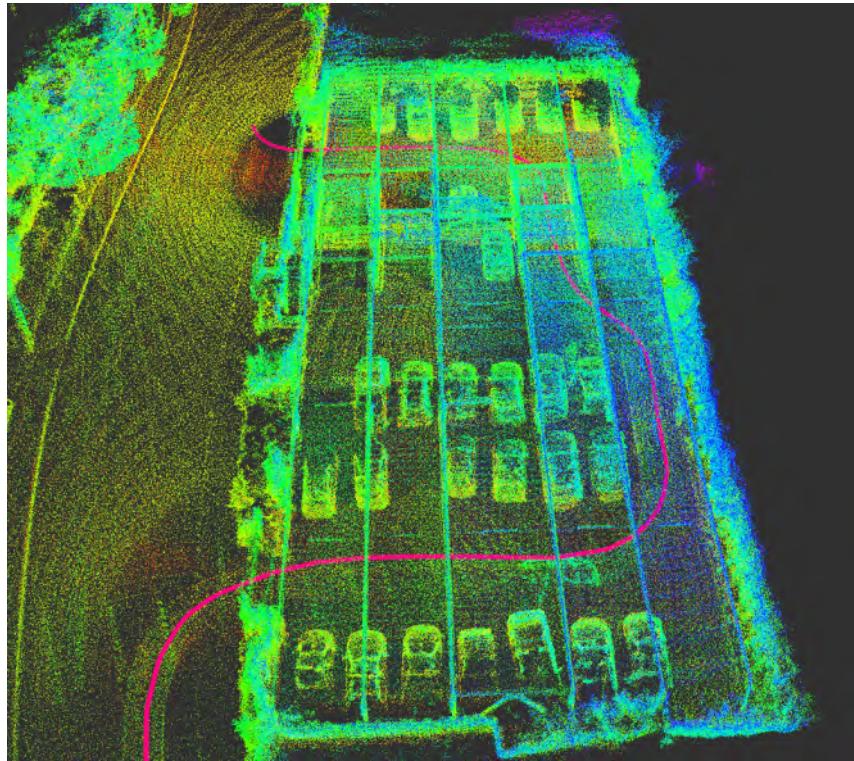


Abbildung 8: Ausschnitt der erzeugten Punktwolkenkarte in Vogelperspektive beim Durchfahren eines Parkhauses; die rote Linie zeigt die während der Kartierung gefahrene Trajektorie.

tale Genauigkeit von rund 0,20 m (1σ) erreicht. Die maximale beobachtete Abweichung lag bei unter 1 m, selbst in vollständig GNSS-abgeschatteten Bereichen wie Tunneln und Parkhäusern, s. Abb. 9. Im Vergleich dazu zeigt eine reine LiDAR-basierte Positionierung ohne INS-basierte Filterung Standardabweichungen von ca. 2 m sowie deutlich höhere Spitzenfehler. Das entwickelte Verfahren reduziert diese Unsicherheiten somit um den Faktor 3–10, abhängig vom Szenario. Gleichzeitig ermöglicht es die Bewertung des Prüfsystems mit einer wesentlich höheren zeitlichen Auflösung, als dies mit klassischen Landmarken-basierten geodätischen Bezugspunkten möglich wäre.

Insgesamt ermöglicht das Verfahren eine robuste und reproduzierbare Verifikation von Lokalisierungslösungen unter realen GNSS-Störbedingungen. Die erzielten Ergebnisse belegen, dass mit der entwickelten Methode eine objektive Bewertung der Positions- und Geschwindigkeitsgenauigkeit von Prüflingen über die gesamte Trajektorie – und nicht nur punktuell – möglich ist. Damit stellt das Konzept einen zentralen Beitrag zur Qualifizierung moderner Navigations- und Sensordatenfusionsverfahren in sicherheitskritischen Anwendungen dar.

1.2.1.4. Datenakquisition in diversitären Verkehrsszenarien

Zur Entwicklung und Bewertung der im Projekt verfolgten Lokalisierungs- und Sensorfusionsverfahren wurden umfangreiche Messfahrten in unterschiedlichen Verkehrsszenarien durchgeführt. Ziel war es, Datensätze zu generieren, die ein breites Spektrum realer Betriebssituationen abdecken und insbesondere Szenarien berücksichtigen, in denen herkömmliche GNSS- oder rein

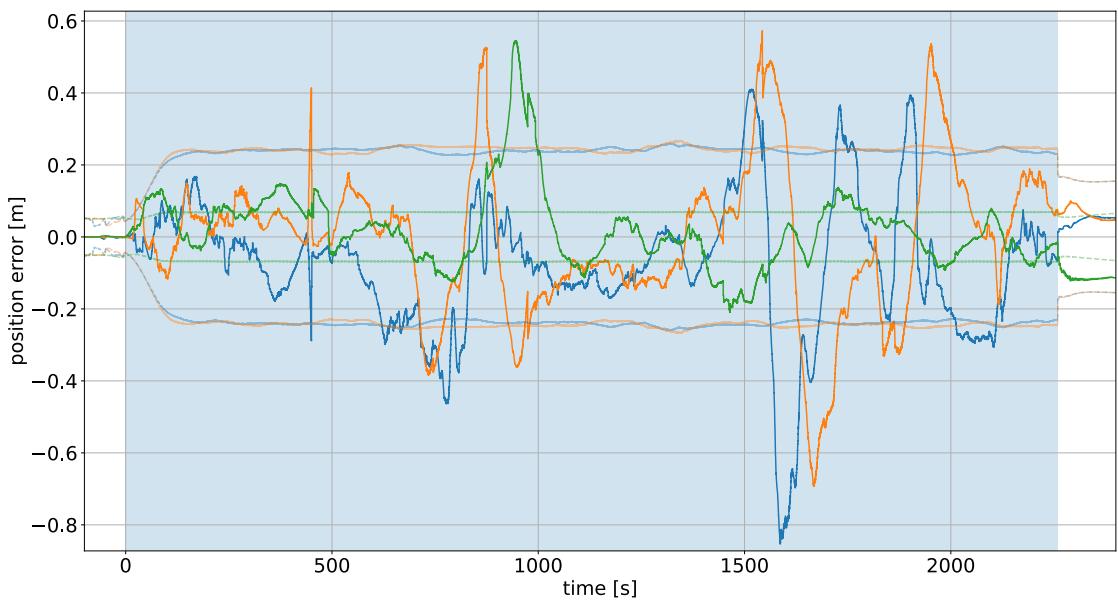


Abbildung 9: Positionsfehler der erzeugten Ground-Truth-Trajektorie (INS/LiDAR) relativ zur INS/RTK-GNSS-Referenz. Farbkennzeichnung der Fehlerverläufe: Blau – Fehler in Nordrichtung, Orange – Fehler in Ostrichtung, Grün – Fehler in Höhenrichtung. Die gestrichelten Linien stellen die geschätzte Standardabweichung der jeweiligen Achsen dar.

LiDAR-basierte Verfahren an ihre Grenzen stoßen. Dies erfolgte in enger Zusammenarbeit mit der Universität Göttingen. Eine gemeinsame wissenschaftliche Veröffentlichung ist in Planung, um die erzielten Ergebnisse der Open-Source-Community zugänglich zu machen (siehe 1.2.4.4).

Erfasst wurden innerstädtische Bereiche mit dichter Bebauung und ausgeprägten Multipath-Effekten, Wohngebiete mit geringen strukturellen Merkmalen, Parkhäuser und Tunnelsysteme mit vollständiger GNSS-Abschattung sowie ländliche Streckenabschnitte mit geringen Landmarkendichten. Zusätzlich wurde eine Vielzahl von Verkehrssituationen mit bewegten Objekten – wie parallel fahrende Fahrzeuge, Gegenverkehr, parkende Fahrzeuge oder Engstellen – berücksichtigt, um die Robustheit der Algorithmen unter dynamischen Randbedingungen zu evaluieren. Die Datensätze enthalten synchronisierte LiDAR-, inertiale und – sofern verfügbar – GNSS-Messungen in hoher zeitlicher Auflösung und bilden sowohl einfache als auch besonders herausfordernde „corner cases“ ab. Dazu gehören beispielsweise Szenarien ohne eindeutige strukturierte Umgebung, enge Tunnelquerschnitte, stark repetitive Umgebungsgeometrien sowie Bereiche mit abrupt wechselnder Umfeldstruktur. Diese Daten bilden die Grundlage für die Validierung der SLAM- und Odometrieverfahren, die Bewertung der GNSS-denied-Lokalisierung sowie die Ableitung von Anforderungen an Driftbegrenzung, Datenfusion und Outlier-Behandlung.

Durch die systematische Erfassung dieser diversitären Verkehrsszenarien steht ein qualitativ hochwertiger, konsistenter und umfassender Datensatz zur Verfügung, der sowohl für die algorithmische Weiterentwicklung im Projekt als auch für externe Forschungsvorhaben eine wertvolle Grundlage darstellt. Die Messdaten ermöglichen eine belastbare Analyse der Leistungsfähigkeit der entwickelten Verfahren unter realistischen und sicherheitskritischen Einsatzbedingungen.

1.2.2. Valeo Schalter und Sensoren GmbH

1.2.2.1. Aufbau und Erweiterung der Versuchsträger

Im Rahmen des Projekts wurde ein VW ID.4 von Valeo als Versuchsträger bereitgestellt und durch den erfahrenen Servicedienstleister IAV GmbH umfassend umgerüstet. Diese Umrüstung war notwendig, um die geplanten Versuchsmessungen und Funktionsentwicklungen im Kontext des Projekts durchführen zu können.

Die detaillierte Planung der notwendigen Umbauten wurde zu Beginn des Projekts sorgfältig erstellt und ist, als wesentliche Grundlage für die Projektumsetzung, in der Abbildung 10 auszugsweise dokumentiert. Diese Planung umfasste die Spezifikation der zu integrierenden Messtechnik, der Energieversorgung und der notwendigen Schnittstellen.

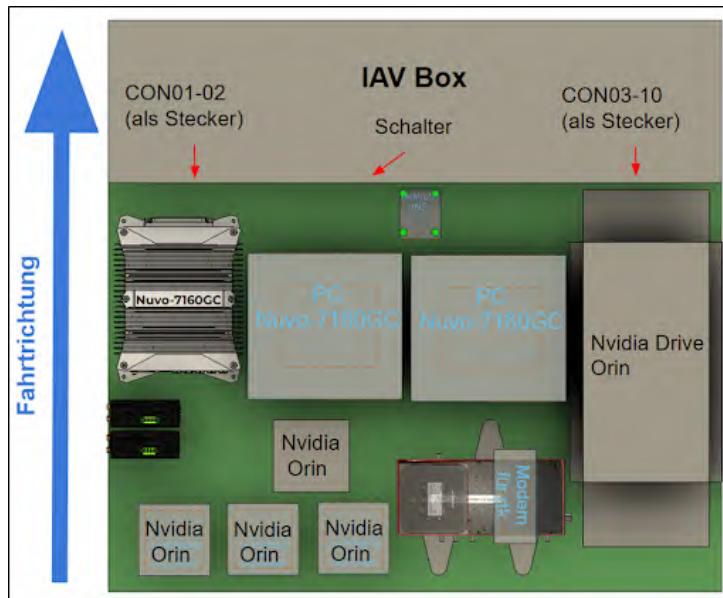


Abbildung 10: Geplante Umrüstung des Valeo-Fahrzeugs.

Die ersten Aufbauten und die damit verbundene Inbetriebnahme der Komponenten erfolgten zunächst testweise in einer Laborumgebung. Dieser Schritt war entscheidend, um die Installation und Entwicklung spezifischer Softwarekomponenten vornehmen zu können. Darüber hinaus ermöglichte das Labor-Setup eine vorläufige und optimierte Verdrahtung der komplexen Messsysteme. Nach erfolgreichen Labortests und der Sicherstellung der Systemfunktionalität stand als nächster wichtiger Schritt die physische Integration dieser Aufbauten in das Zielfahrzeug an.

Nach der Rückkehr des Versuchsträgers vom Aufbau konzentrierten sich die Arbeiten zunächst auf die intensiven Tests der neu implementierten Funktionen. Ein kritischer Aspekt hierbei war die Überprüfung der Energieversorgung für die umfangreiche, zusätzlich zu installierende Messtechnik. Die Integration in ein reines Elektrofahrzeug (BEV) stellte hierbei eine besondere Herausforderung dar: Es muss zwingend beachtet werden, dass das gesamte fahrzeugeigene Niederspannungsnetz nur mit einer maximalen Zusatzleistung von 1 kW belastet werden darf. Diese signifikante Einschränkung war bei der Konzeption und Umsetzung aller weiteren Schritte strikt einzuhalten, um die Stabilität und Sicherheit des Fahrzeugbetriebs nicht zu gefährden.

Die Gesamtheit der durchgeführten Umrüstungsmaßnahmen ist im Detail in Abbildung 11 veranschaulicht. Im Anschluss an die erfolgreiche Umrüstung wurde die essenzielle Kalibrierung und Synchronisation aller neu integrierten Sensoren in den Versuchsfahrzeugen durchgeführt, um präzise und verwertbare Messdaten zu gewährleisten.



Abbildung 11: Umrüstung des Valeo-Fahrzeugs. Der Kofferraumaufbau der neu umgesetzten Hardware.

Parallel zu den Fahrzeugumbauten erfolgten Testfahrten und Sensordaten Aufnahmen auf dem benötigten Testgelände, namentlich der Autobahn A81. Hierbei wurden auch bereits vorhandene Bestandskartendaten kritisch geprüft und die notwendigen Kartendaten in den erforderlichen, nutzbaren Dateiformaten bereitgestellt. Die detaillierten Vergleiche und die tiefgreifende Analyse der systematischen Fehlermoden, die sich aus diesen Kartierungsarbeiten ergaben, sind separat und ausführlich der Analyse zu systematischen Fehlermoden in 1.2.2.3 aufgeführt.

1.2.2.2. Aufbau einer Visualisierung von hochgenauen Karten

Die erste Aufgabe in AP 6, die als Grundlage für die Durchführung aller weiteren Teilaufgaben dient, bestand im Aufbau einer 3D-Visualisierung hochpräziser Karten- und Sensordaten auf Basis von OpenGL [19]:

- Die Entwicklung einer echtzeitfähigen Darstellung aller Daten sowie Vor- und Rückspul-Optionen um Szenen genau zu inspizieren (HD Karte, Kamera, Lidar, Radar, Fahrzeugdaten).
- Die Entwicklung einer Anzeige von Referenzdaten und Annotationen. Diese umfasst die Auswahl der anzuzeigenden Daten mit detaillierten Informationen.
- Die Integration einer intelligenten Lineal- und Zeichen-Funktion in 3D.
- Die Integration eines dynamischen Wechsels zwischen Master-Zeitsignalen, auf deren Basis Daten zeitlich angezeigt werden.

Alle Anforderungen wurden entsprechend des Plans umgesetzt, und weitere Features, die im Projektverlauf hinzugekommen sind, wurden implementiert. Hinsichtlich der Kartendaten ist zu berücksichtigen, dass während des Projektverlaufs verschiedene Arten von HD-Karteninformationen zur Verfügung standen. Sowohl reine Punktwolkendaten als auch HD-Kartenformate, insbesondere mit Fokus auf OpenDrive und OSM, wurden evaluiert. Zu Projektbeginn wurde die

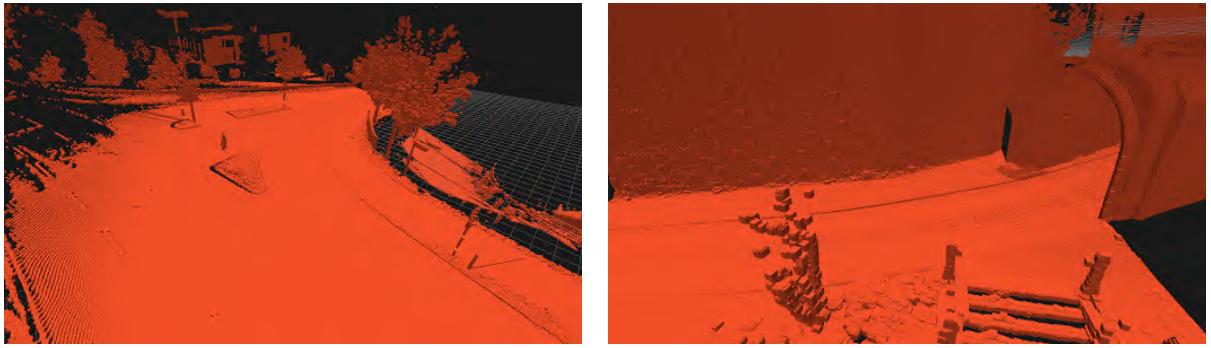


Abbildung 12: Visualisierung der Daten zweier Punktwolkenaufnahmen von 3D Mapping Solutions.

Basisvisualisierung statischer, großflächiger Punktwolken implementiert. Ein Beispiel dieser Daten ist in Abbildung 12 dargestellt.

Da die Datenmenge über alle Dateien dynamisch schwer zu handhaben ist, wurde ein voxelbares Downsampling implementiert, welches in Abbildung 13 zu sehen ist. Des Weiteren wurde in der Visualisierung eine Unterteilungsmethode implementiert, welche eine dynamische Begrenzung der visualisierten Datenmengen basierend auf dem Sichtbereich in der Szene ermöglicht.

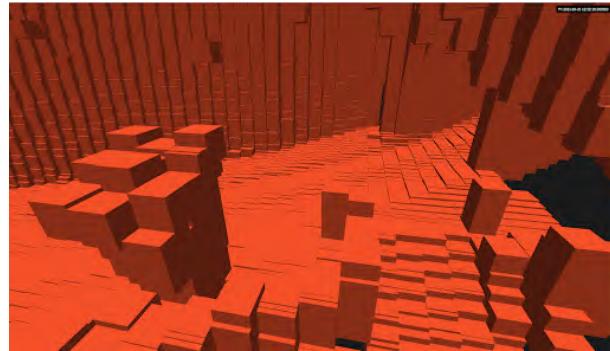


Abbildung 13: Visualisierung der Daten einer reduzierten Punktwolkenaufnahme von 3D Mapping Solutions aus mehreren zusammengefügten Files. Die Abbildung referenziert das zweite Bild aus Abbildung 12.

Ein weiteres wichtiges Feature war die Handhabung von HD-Karten im OpenDrive Format: Zunächst wurden grundlegende Geometrien, wie beispielsweise Fahrspuren, die für die im Projekt geplanten Funktionen erforderlich sind, betrachtet. Diese werden in der OpenDrive-Karte mittels einer Referenzlinie in lokalen Koordinaten und orthogonal zu dieser verlaufenden Distanzen dargestellt. Durch eine Koordinatentransformation können diese lokalen Informationen in geographische Koordinaten überführt werden. Eine Illustration der Referenzlinien und der zugehörigen Geometrien ist in Abbildung 14 dargestellt. Darüber hinaus wurden die Profile dekodiert und erfasst, welche unter anderem den Höhenverlauf entlang und orthogonal zur Referenzlinie sowie den Umriss von Objekten und Signalen, wie beispielsweise Verkehrszeichen, beschreiben.

Die grundlegende Visualisierung der nachfolgenden Kartenelemente aus dem OpenDrive-Format wurde in OpenGL erstellt und lässt sich vereinfacht mit den folgenden Hauptelementen zusammenfassen:

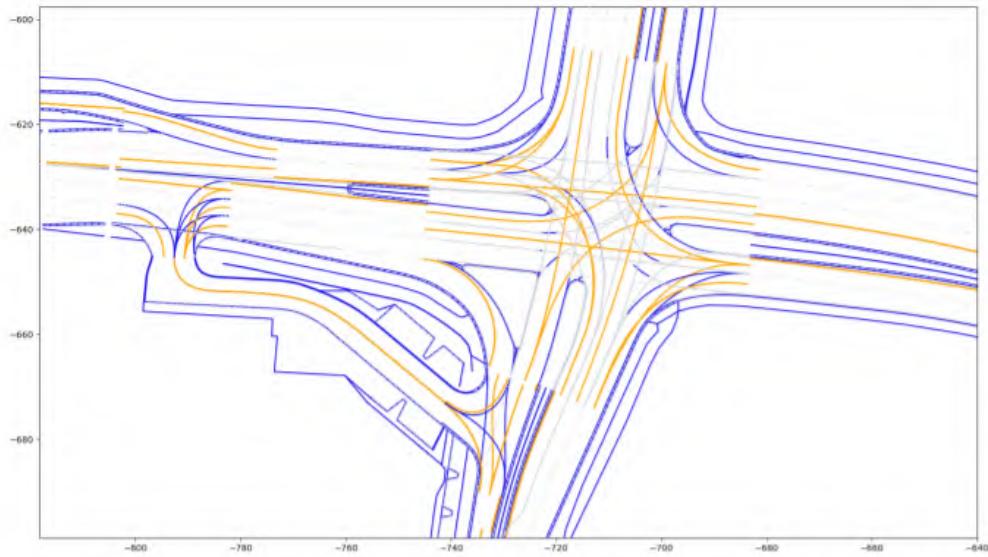


Abbildung 14: Beispiel einer Visualisierung der grundlegenden Karteninformationen einer Kreuzung mit verschiedenen Fahrspuren sowie Fußgängerbereiche. Visualisiert sind die Referenzlinien der Straßen in Orange und die dazu relativ befindlichen Linienzüge, welche z.B die Grenzen von Fahrspuren darstellen.

- **Straßen:** Dies umfasst Fahrspuren (Lanes) sowie symbolische Darstellungen wie Spurmarkierungen. Dabei wurden auch die komplexen Höhenprofile, die das OpenDrive-Format bereitstellt, berücksichtigt.
- **Signale:** Hierzu zählen Schilder als Oberflächenelemente etc.
- **Objekte:** Dies beinhaltet beispielsweise Bäume, Gebäude und Pfeiler. Bei allen Objekten, die durch ihre 2D-Umrundung dargestellt werden, wurde zusätzlich eine Triangulation der Oberflächen implementiert, um unter anderem komplexe Spurmarkierungen wie Spurpfeile, Mauern oder Häuser präziser abzubilden.

Ferner wurde für jedes der berücksichtigten Kartenelemente die Option hinzugefügt, diese über ein Kontextmenü dynamisch zu aktivieren oder zu deaktivieren. Ein Beispiel dieser Visualisierung ist in Abbildung 15 dargestellt, während die Überlagerung der reduzierten Punktwolkenaufnahme, die von 3D Mapping Solutions GmbH zur Generierung der Karte selbst genutzt wurde, in Abbildung 16 ersichtlich ist.

Die Visualisierung der Fahrzeugsensordaten wurde auf Basis von Messdaten verschiedener Valeo-Fahrzeuge, einschließlich des umgebauten Versuchsträgers, umgesetzt. Dabei wurden Sensordaten unterschiedlicher LiDAR-Systeme (z. B. Valeo SCALA 1 und 2), Radarsensoren sowie Kameras in den Fahrzeugkoordinaten integriert und visualisiert. Die gemeinsame Darstellung der Sensor- und Kartendaten ist in Abbildung 17 dargestellt.

Es wurden außerdem interaktive Features in der Visualisierung implementiert: Objekte können per Mausklick gewählt werden, und ihre Quelle sowie Zusatzinformationen können angezeigt

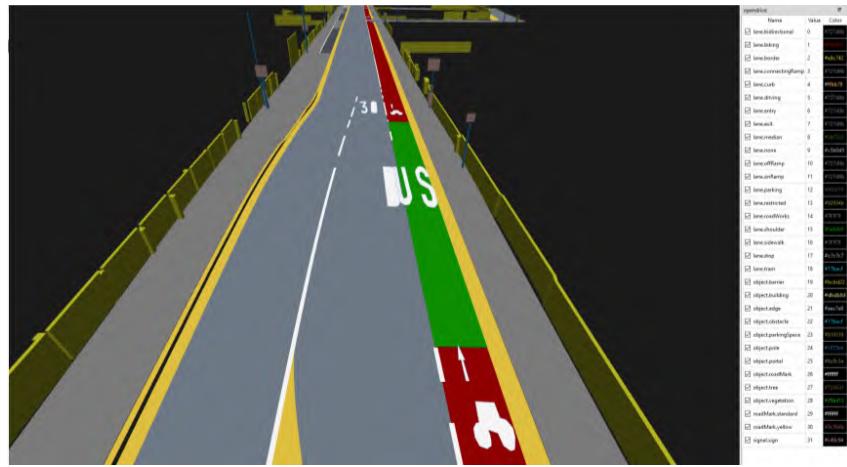


Abbildung 15: Ein Beispiel der Visualisierung von Straßen, Objekten, Schildern, Spurmarkierungen etc. Die Abbildung zeigt einen Ausschnitt auf einer vom Partner DLR öffentlich bereitgestellten OpenDrive Karte in Braunschweig.

werden. Beispielsweise kann die Zuordnung eines LiDAR-Punktes zu ihrem Sensor erfolgen. Hinzu kommt eine Linealfunktion, welche das Verbinden zwischen Objekten in der Szene erlaubt, um in der Debugumgebung generelle Messfunktionalität zu erlauben.

Eine Illustration dieser interaktiven Elemente ist in Abbildung 18 beigelegt. Eine 2D-projizierte Darstellung in der Vogelperspektive wurde hinzugefügt und ein dynamischer Wechsel von Standpunkten wurde zusätzlich über Schnelltasten erstellt. Strecken-Segmente mit Brücken oder Tunnels lassen sich zusätzlich kennzeichnen, wie in Abbildung 19 dargestellt.

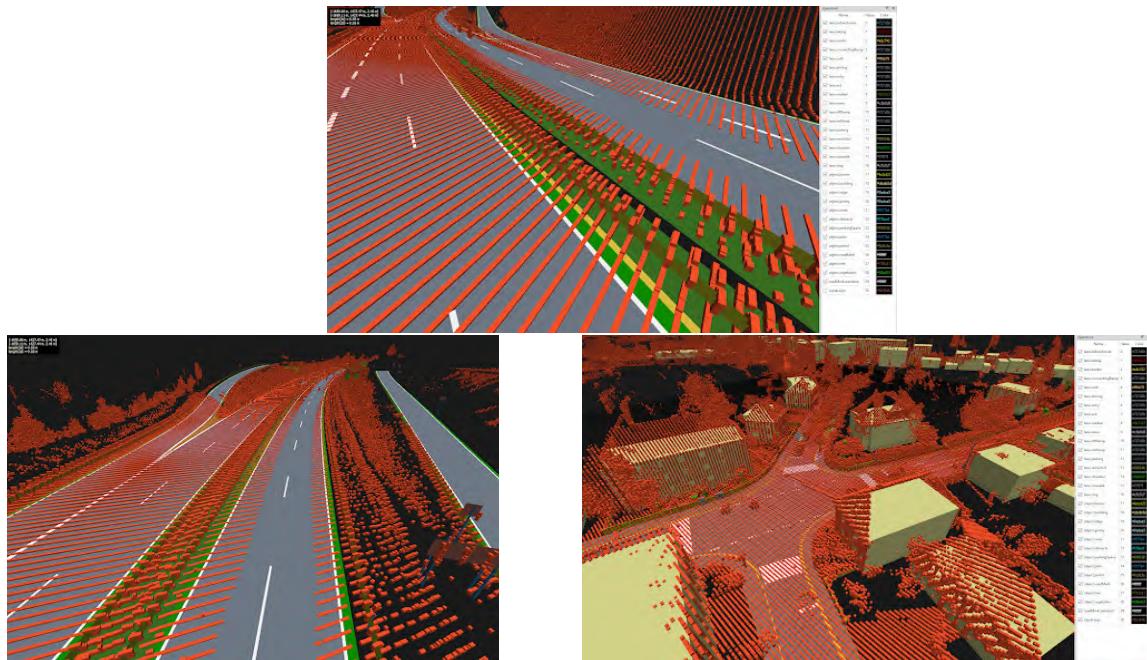


Abbildung 16: Visualisierung der Daten zweier Punktwolkenaufnahmen von 3D Mapping Solutions.

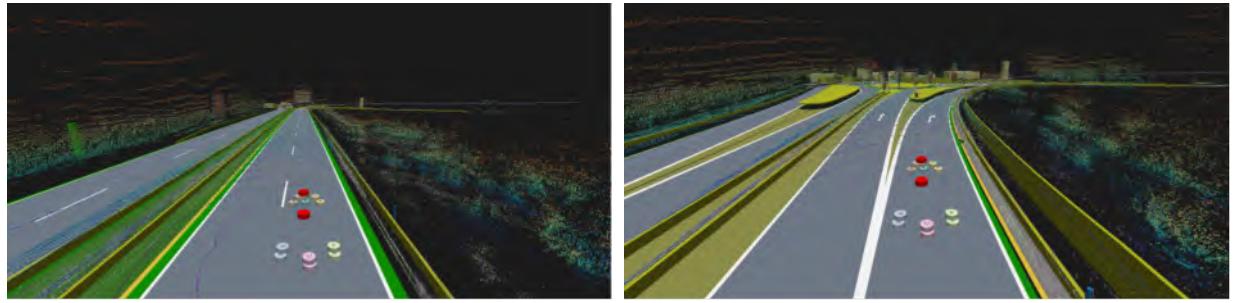


Abbildung 17: Gemeinsame Darstellung der Karte des OpenDrive-Formats und der Sensordaten eines älteren Valeo-Fahrzeugs. Zu sehen sind die Sensordaten des gesamten Aufnahme-Setups als Punkte in verschiedenen Farben. Hinzu kommt die OpenDrive-Karte mit ihren Elementen. Die Sensoren, deren Messungen gezeigt werden, sind als flache Zylinder in verschiedenen Farben angezeigt.

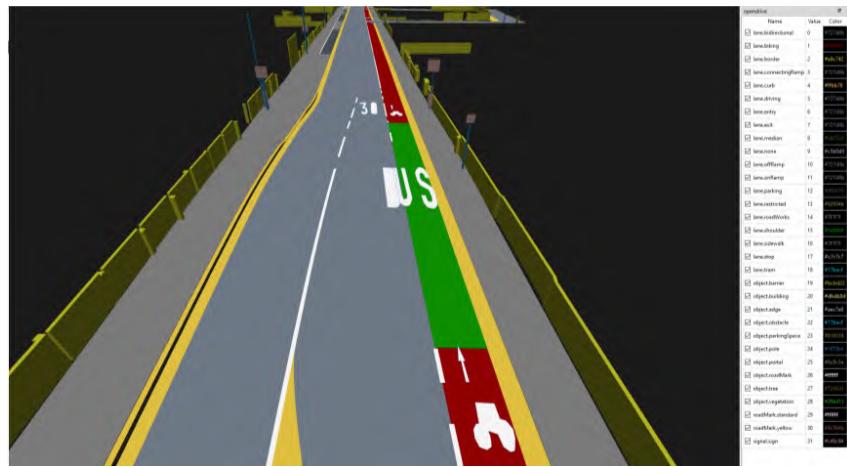


Abbildung 18: Ein Beispiel der Visualisierung von Straßen, Objekten, Schildern, Spurmarkierungen etc. Die Abbildung zeigt einen Ausschnitt auf einer vom Partner DLR öffentlich bereitgestellten OpenDrive-Karte in Braunschweig.

1.2.2.3. Analyse zu systematischen Fehlermoden

Zur Vorbereitung der Verwendung der HD-Karte in der Umfelderfassung wurden in AP 6 systematische Fehlermoden in Kartendaten analysiert. Weiterhin wurden KI-basierte Verfahren zur Bewertung und Auswahl (sog. Outlier-Detection) der Sensor- und Kartendaten, u.a. im Hinblick auf eine Rekonfigurierbarkeit (z.B. bei systematischen Fehlern oder temporär verminderter Datenqualität) entwickelt.

Um diese Aufgabe zu bearbeiten, wurden Kartendaten in verschiedenen Darstellungen in Betracht gezogen. In einer ersten Analyse wurden OpenDrive-Kartendaten auf ihre Darstellungsmöglichkeiten manuell geprüft. Diese Analyse wurde dann als Basis für die Entwicklung weiterer Tools herangezogen. Auf Basis der Punktwolkenaufnahmen von 3D Mapping Solutions und der daraus generierten OpenDrive-HD-Karte konnten Limitationen der Darstellung und Detailtreue analysiert werden. Wie erwartet, ist die Darstellung komplexer Objekte nur mit gewissen Abstraktionen gewährleistet. In Abbildung 16 wurde dies exemplarisch aufgezeigt.

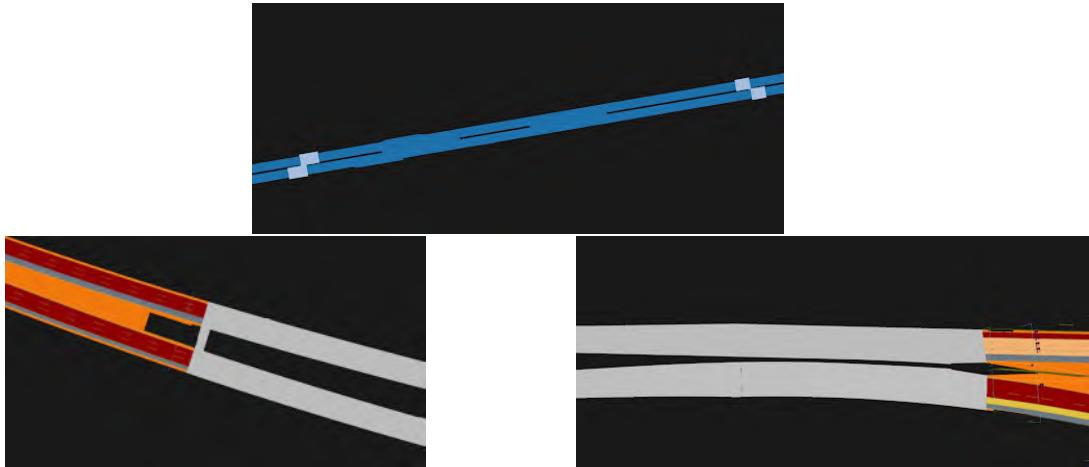


Abbildung 19: Beispiel der Einfärben-Option auf ein Segment mit Brücken. Die Straße ist dunkelblau gefärbt, um das Segment als Brücke zu kennzeichnen, und die Brückenabschnitte sind als hellblaue Abschnitte eingezeichnet. Selbiges gilt für die Segmente mit Tunnels, bei denen die Straßen mit Tunnels rötlich eingefärbt wurden und die Bereiche des Tunnels als Grau.

Analysen Fundamentaler Fehlermoden

Abweichungen in den Objektbeschreibungen lassen sich bereits an einfachen Beispielen erkennen: Gebäude werden in der Regel über ihre Grundrisse definiert, während Tunnel oder Brücken lediglich durch vereinfachte Konturen dargestellt sind. Diese unterschiedlichen Abstraktionsebenen stellen an sich keine Fehler dar, erschweren jedoch den Vergleich mit der Karte in diesen Bereichen. Bei Kartenabgleichen sollten daher beispielsweise Varianzen in den Oberflächen berücksichtigt werden. Zudem ist zu beachten, dass Verkehrsinseln nicht als Teil der Straßoberfläche, sondern als eigenständige Objekte modelliert sind. Für diese Szenarien sind einige Vergleichsbilder in Abbildung 20 zu finden.

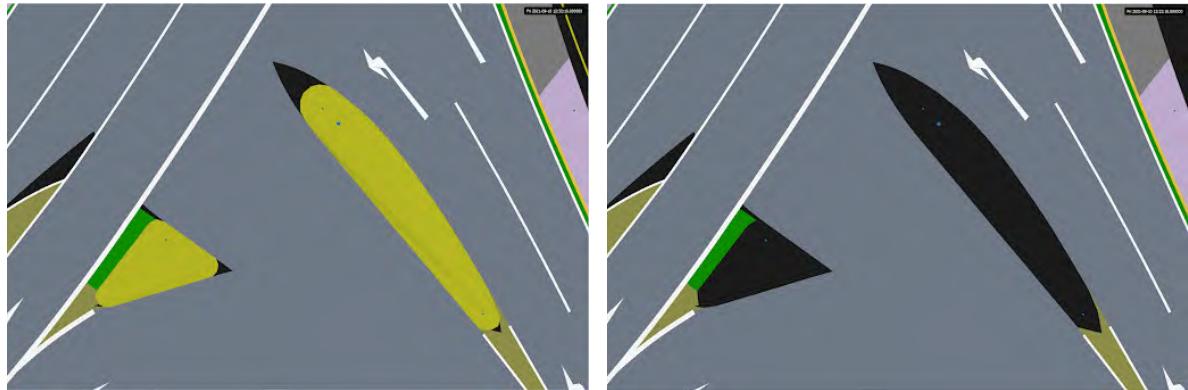


Abbildung 20: Beispiel von Oberflächen und Verkehrsinseln an einer Kreuzung. Die linke Abbildung zeigt die Umgebung um verschiedene Verkehrsinseln mit der Repräsentation ihrer Objekte. Die rechte Abbildung zeigt die Lücken, die ohne die Verkehrsinseln in der Karte entstehen.

Des Weiteren sind auch parkenden Fahrzeuge in den Rohdaten vorhanden und erschweren den Abgleich zur Karte. Es konnten auch leichte Limitationen in der Ausdrucksstärke einiger

Geometrien der Karte festgestellt werden: So sind beispielsweise kleinere Fehler in der Darstellung der Polynome der Umrisse von z.B. Spurmarkierungen aufzufinden, wie in Abbildung 21 zu sehen ist.

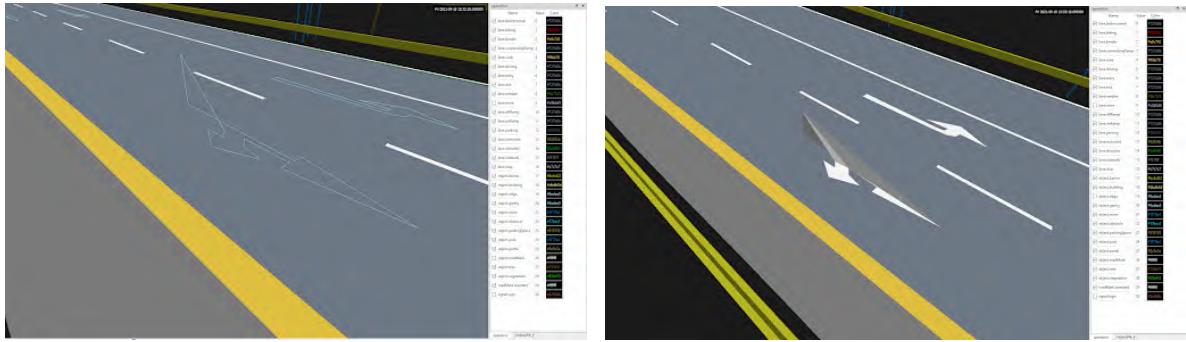


Abbildung 21: Die Abbildung zeigt die Spurmarkierung und ihre triangulierte Fläche. Dabei ist zu erkennen, dass das Polygone an einem Punkt eine erhöhte Position besitzt, die nicht existieren dürfte.

Um weiter zu prüfen, ob diese Fehler auch in der generellen Interpretation des OpenDrive vorkommen oder ob es sich noch um Fehler in der entwickelten Visualisierung handelt, wurde ein Referenzprogramm hinzugezogen [20]. Die gefundenen Fehler und weitere Fehler sind auch konsistent in diesem zu finden. Abbildung 22 zeigt Beispiele von neu entdeckten Fehlern in der Kartendarstellung aus verschiedenen Beispielkarten.

Analysen A81

Im Verlauf des Projekts wurden dann die projektrelevanten Kartendaten der A81 von Bietigheim-Bissingen bis zum Kreuz Leonberg bereitgestellt. Diese wurden mit den zuvor generierten Erkenntnissen und der entwickelten Visualisierung auf ähnliche systematische Fehler geprüft.

Aus internen Kartendaten von Valeo wurden ältere und neuere Versionen überlappender Segmente desselben Gebiets miteinander verglichen, die zu unterschiedlichen Zeitpunkten erstellt wurden, um systematische Veränderungen der Kartendaten im Zeitverlauf zu analysieren. Der betrachtete Zeitraum umfasst etwa zwei Jahre. Dabei wurden gezielt Bereiche ausgewählt, in denen umfangreiche bauliche Veränderungen stattgefunden haben. Abbildung 23 zeigt exemplarisch Teile dieser systematischen Änderungen.

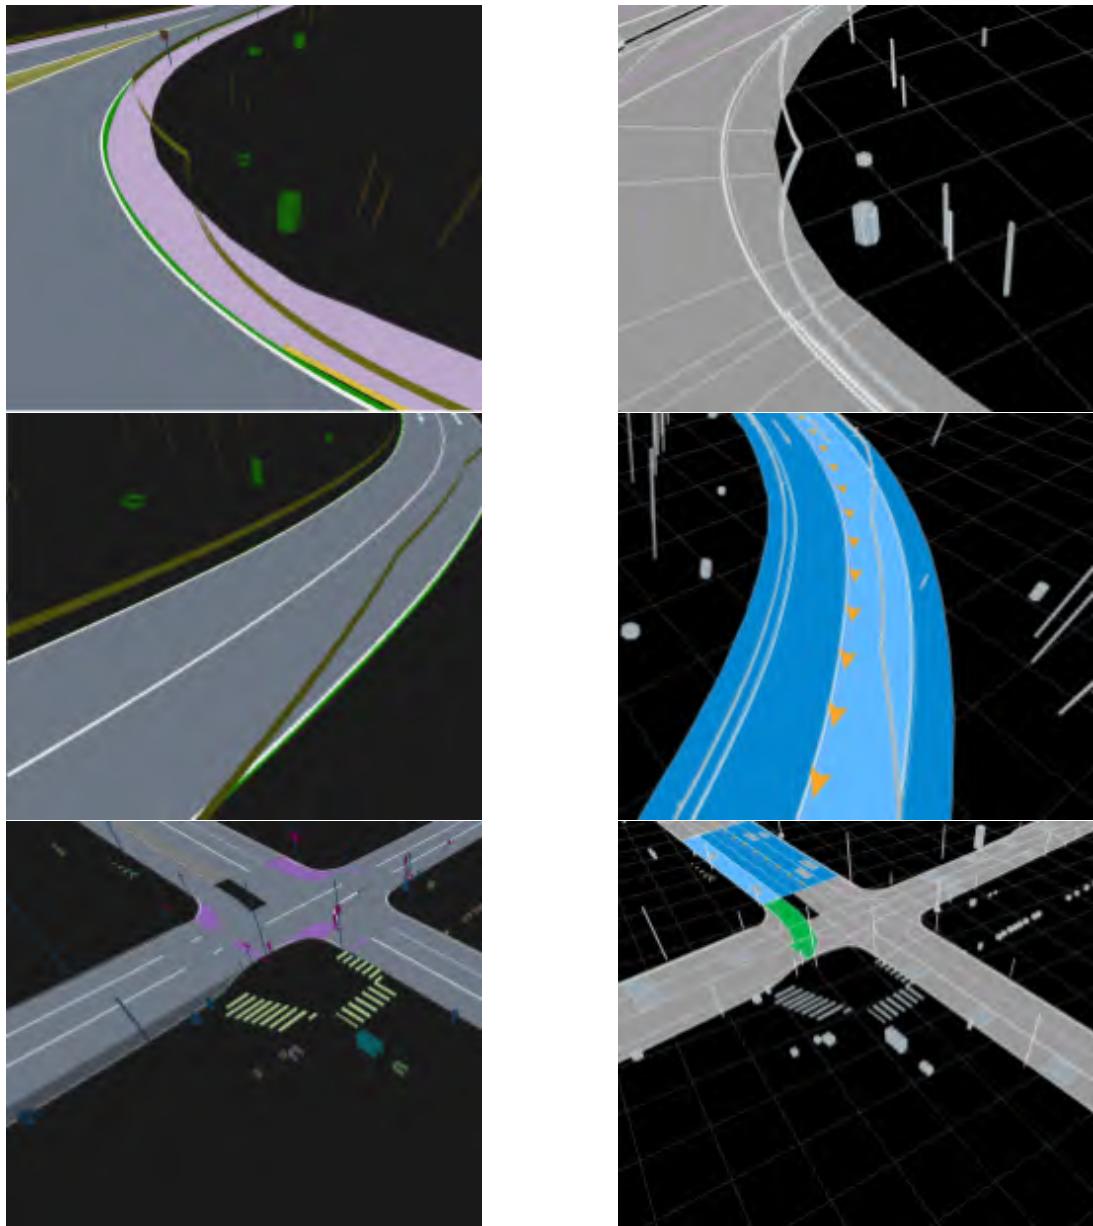


Abbildung 22: Fehlerhafte Profile in einer Referenzdarstellung und die Darstellung der für das Projekt entwickelten Visualisierung. Die linke Spalte zeigt die im Rahmen des Projekts entwickelten Visualisierung, die rechte Spalte zeigt die Referenzkarte. Die ersten zwei Zeilen zeigen fehlerhafte Leitplanken und das dritte Bild zeigt fehlerhaft definierte Höhen von Objekten und Markierungen, wie Zebrastreifen.

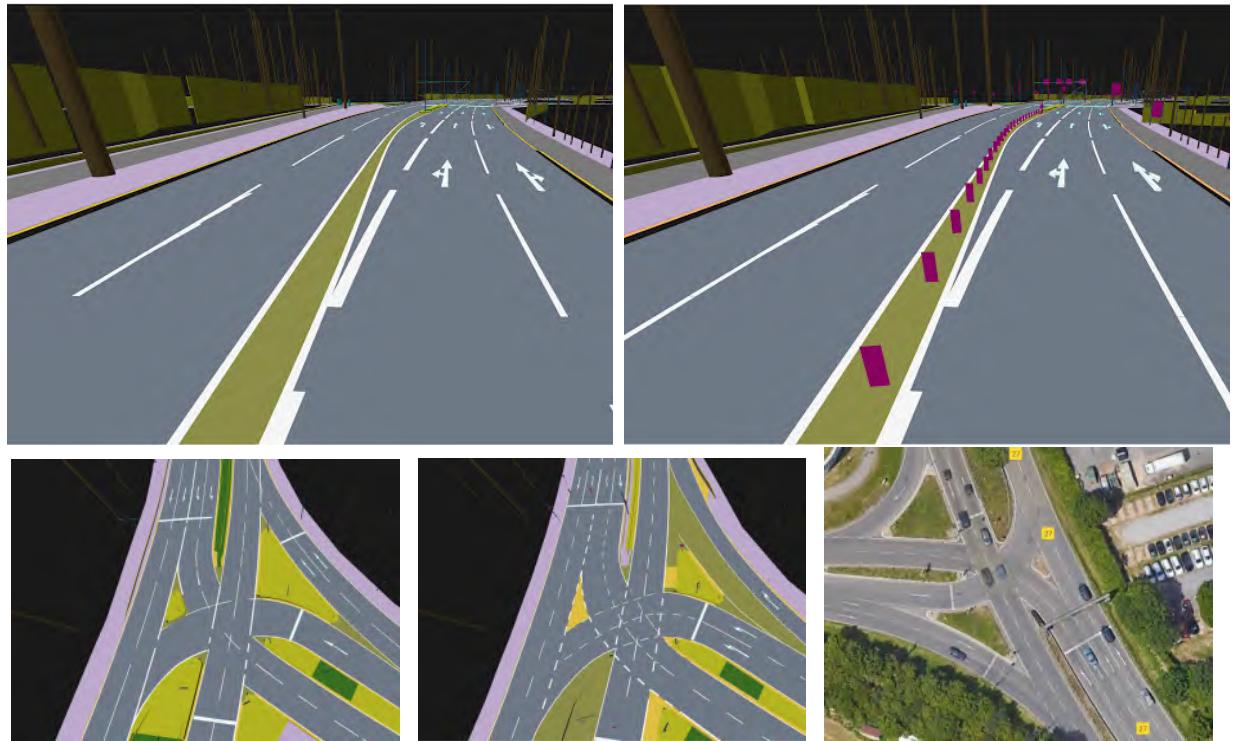


Abbildung 23: Beispiel von Änderungen im Kartenmaterial nach signifikanten Umbauten von Straßenschildern und der generellen Streckenführung inklusive Verkehrsinseln.

Darüber hinaus konnten mit Hilfe der im Projekt entwickelten Visualisierung systematische Fehler in den neueren internen Kartendaten identifiziert werden. Beispielsweise wurden fehlerhafte Geometrien gefunden, wie in den Abbildungen 24 und 25 dargestellt. Für die Reviewer im Projekt erwies sich die Visualisierung als besonders hilfreich, da sie es ermöglichte, Kartendaten verschiedener Versionen übereinander zu legen und einzelne Kartenebenen bei Bedarf dynamisch zu aktivieren oder zu deaktivieren.

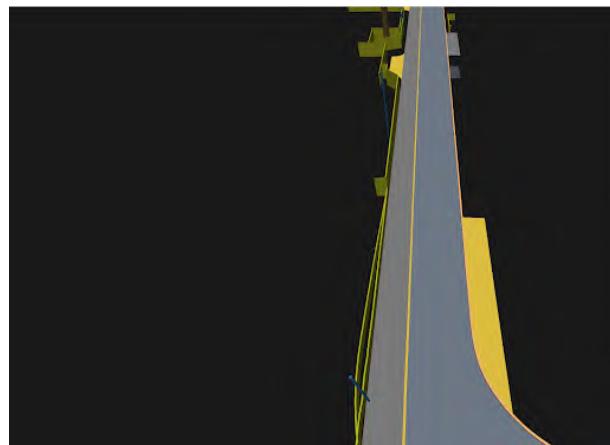


Abbildung 24: Beispiel fehlerhafter Objektgeometrien, die durch die Visualisierung aufgedeckt wurden. Die Abbildung zeigt die Überlagerung der alten und neuen Karte des selben Segments; an der linken Straßenseite befindet sich dabei ein Zaun, der in einer geraden Linie verläuft. Während die ältere Karte dies korrekt darstellt, ist eine Diskrepanz in der neuen Karte zu sehen, bei der dieser Zaun eingedellt ist.



Abbildung 25: Beispiel fehlerhafter Objekte, hier Pfosten, die durch die Visualisierung aufgedeckt wurden. Dabei sind auf Autobahnspuren Pfosten eingetragen, die nicht existieren und Probleme bei Fahrfunktionen erzeugen würden.

Um Daten der systematischen Änderung basierend auf Fahrzeugdaten zu prüfen, wurden während der Umbauphase des Engelbergtunnels Testfahrten durch die zugehörige Baustelle durchgeführt. Dies erlaubte, Änderungen der Umgebung und entsprechende systematische Fehler bei zwei Karten zu untersuchen. Die Karte der A81 wurden in mehreren Nachbesprechungen mit dem Kartenzulieferer 3D Mapping Solutions GmbH verbessert und abgenommen.

Analyse Schwarzer Berg

Obwohl der Fokus von Valeo auf der Karte des Testfelds A81 lag, wurde die Analyse auch auf die Karte „Schwarzer Berg“ im Stadtgebiet Braunschweig ausgeweitet. Letztere geschah in Zusammenarbeit mit dem Partner DLR.

Hierbei wurden insbesondere Unregelmäßigkeiten der Daten im Bereich der Tramlinien identifiziert. Diese sind von besonderer Bedeutung für den Partner DLR, um die Bewegungen der Tram anhand der Schienen zu prädizieren. Tramlinien sind jedoch keine eigenständigen Straßen im Sinne des OpenDrive Formats, sondern Spuren, die an den Verlauf von Straßensegmenten gekoppelt sind. Damit gehen einige anschauliche Implikationen einher:

- Einzelne Segmente der Tramlinien sind teilweise weder durch Linking noch durch Geometrien verbunden. Sie beschreiben somit unabhängige Segmente, die für die Zielfunktion nicht zu verwenden sind. Abbildung 26 zeigt die extrahierten Tramlinien und Zooms auf die problematischen Lücken.
- Die Richtungen der einzelnen Segmente sind an den Segment-Übergängen nicht glatt zwischen den angrenzenden Segmenten. Das heißt, dass diese nicht konsistent in dieselbe Richtung zeigen, wie in Abbildung 27 dargestellt wird.
- Die Breiten der Segmente weisen Inkonsistenzen auf, wie in Abbildung 28 im Vergleich mit Satellitenbildern von Google Maps zu sehen ist.

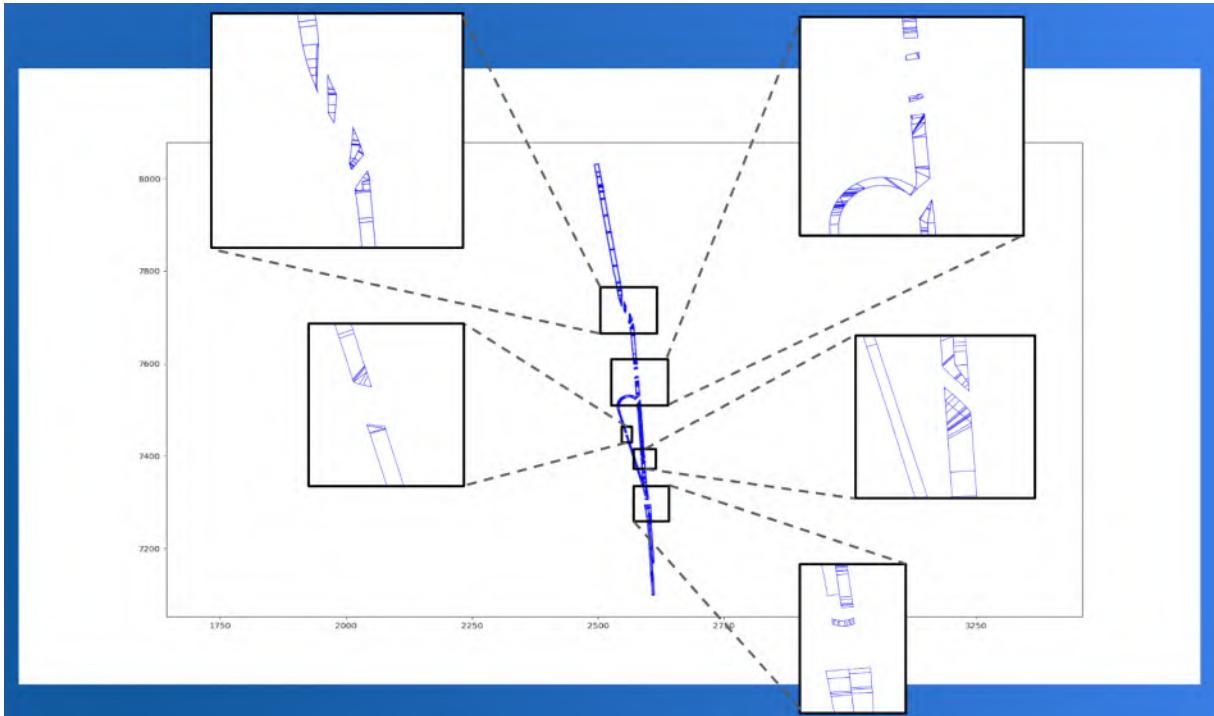


Abbildung 26: Die Tram-Segmente der Karte des Schwarzen Bergs. Es werden diverse Zooms auf den Lücken in den Segmenten dargestellt.

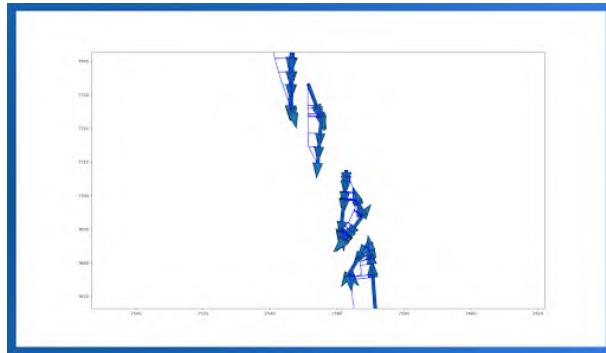


Abbildung 27: Zeigt die Richtungsvektoren der Straßensegmente. Die linke Abbildung zeigt die Vektoren für den Ausschnitt, der in Abbildung 26 oben links angezeigt wird. Die rechte Abbildung zeigt den Ausschnitt, der unten rechts angezeigt wird. In beiden Fällen zeigen die Vektoren der Segmente in unterschiedliche Richtung, speziell in der rechten Abbildung wird sichtbar, dass die Vektoren beinahe orthogonal zu den eingehenden Tramlinien verlaufen.

Um diesen Problemen entgegenzuwirken, wurde eine eigene Erweiterung dieser Profile in Betracht gezogen. Die Idee war dabei, die fehlenden Stücke zu überbrücken, während die bereits bestehenden Segmente beibehalten werden sollten. Dabei gelang es, durch die bestehenden Kartendaten und händische Annotation der Spuren, Patches für die Tramlinien zu erstellen. Eine einfache Machbarkeitsbewertung wurde durchgeführt, indem Linienzüge erstellt und in die Karte eingefügt wurden. Relevante Informationen wie die Höhe der Straßenoberfläche wurden aus der Karte gezogen, um das Profil zu vervollständigen. Als Proof of Concept konnten die

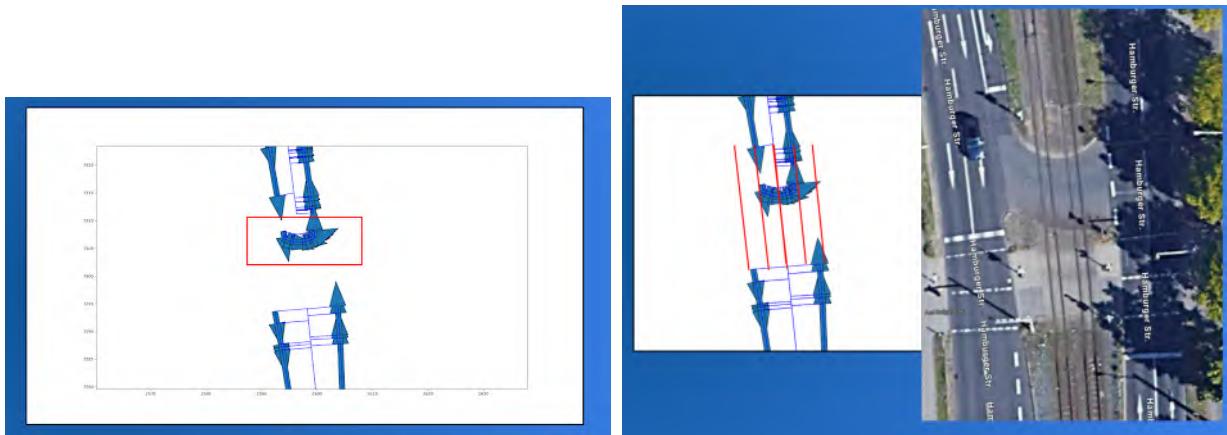


Abbildung 28: Die Tram-Segmente der Karte des Schwarzen Bergs und ein Abgleich gegen ein Satellitenbild. Die Abbildung beinhaltet in rot die erwarteten Fortführungen der Tramlinien und zeigt auch die Größendiskrepanz in dieser auf.

so erzeugten „Patches“ als neues Profil erfolgreich in die Karte integriert werden. Beispiele der erweiterten Patches können in Abbildung 29 eingesehen werden.

Direkte Erweiterungen des Proof of Concept können hier durch komplexere Geometrien des OpenDrive Profiles durch Fitting Methoden erreicht werden, um vollständige Profile zu generieren. Jedoch benötigt eine vollständige Erweiterung der Karte weiteren Entwicklungsaufwand, der aktuell den Rahmen des Projekts übersteigt. Das Feedback, der Proof of Concept, sowie Vorschläge für die weitere Verbesserung der Tramlinien wurden an die Partner, insbesondere das Team des DLR, weitergegeben. Das DLR hat die Erkenntnisse auch für das Feedback an den Kartenprovider verwendet.

Entwicklung automatisierter Kartenverbesserung

Die im Rahmen der systematischen Voruntersuchungen gewonnenen Erkenntnisse führten zu einem unerwarteten Mehraufwand, eröffneten jedoch zugleich vielversprechende Perspektiven für zukünftige Arbeiten im Bereich des Machine Learning. Insbesondere wurden Ansätze zur automatisierten Umgebungsannotation sowie zur Verbesserung von Referenzkarten gängiger State-of-the-Art-Kartenzulieferer für ML-Anwendungen weiterverfolgt. Entsprechend setzte Valeo die Analyse systematischer Fehlermodi in internen HD-Karten fort. Betrachtet wurden hier Datensätze unabhängig vom Projektkontext, z.B. im OSM-Format.

In diesem Kontext hat Valeo einen neuen Algorithmus zur automatischen Erkennung und Behebung von Fehlermodi in HD-Karten erstellt. Dieser Algorithmus ist in der Lage, Inkonsistenzen in der Geometrie von Pfad- und Spurbegrenzungselementen zu finden. Dabei wird beispielsweise eine interpolierte Mittellinie der Spuren erstellt und gegen die Geometrie der Karte verglichen. Auf diese Weise können Diskrepanzen zwischen den erwarteten Spurlinien und der vorliegenden Karte hervorgehoben werden. Die oben beschriebene Interpolation kann zudem als Verbesserung der Mittellinie genutzt werden. Hierbei ist jedoch zu beachten, dass dieser Ansatz keine Stetigkeit der so erzeugten Mittellinien garantiert. Um dies zu gewährleisten, kann ein Spline Fitting verwendet werden. Abbildung 30 stellt eine solche Diskrepanz dar und zeigt die

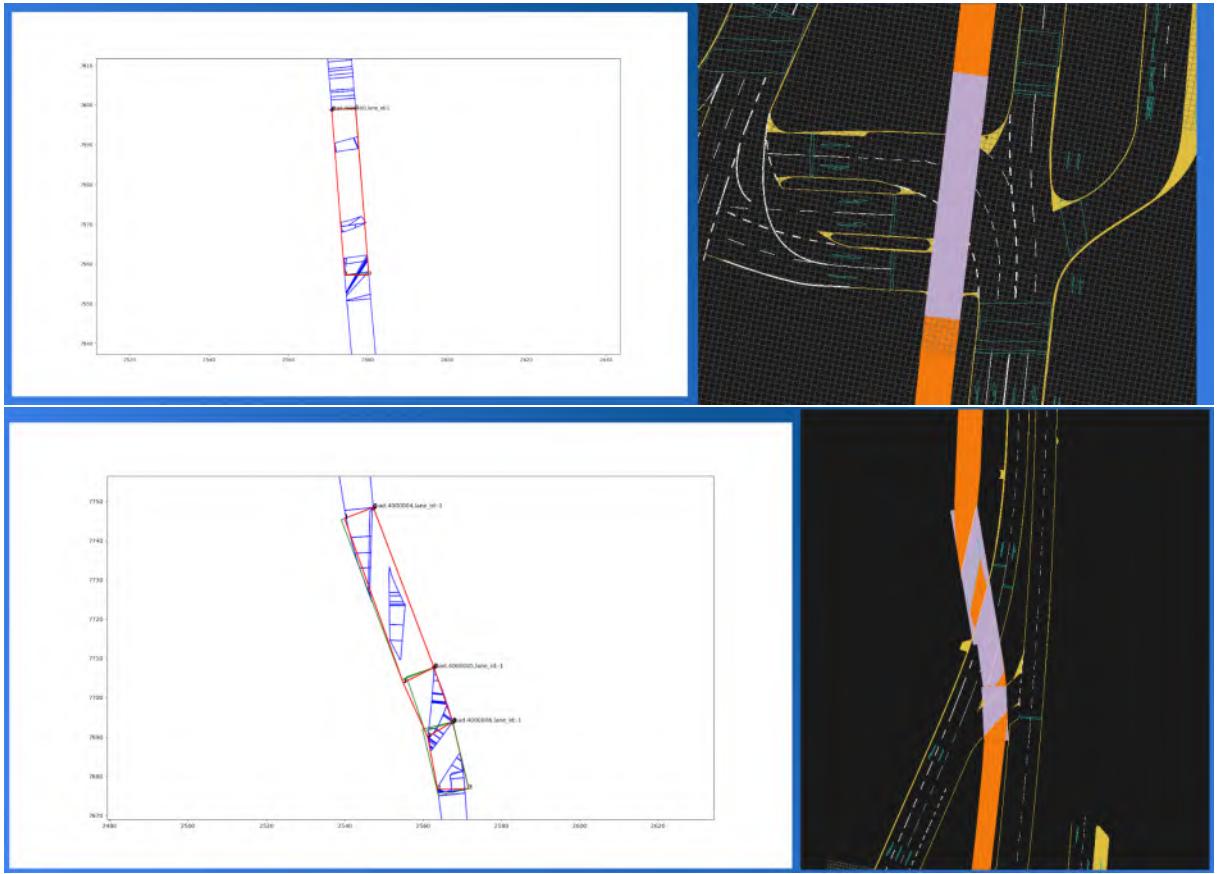


Abbildung 29: Es werden zwei Segmente der Karte gezeigt, auf welchen Problemstellen in den Tramlinien existieren. Die linken Abbildungen zeigen sowohl die Segmente als auch die händisch erstellten Patches, die in die Karte eingefügt werden. Die rechten Abbildungen zeigen die in die Karte eingefügten Segmente in der im Projekt generierten Visualisierung. In Orange werden die bisherigen Segmente der Tramlinien dargestellt und in Lila die hinzugefügten Patches.

durch das Verwenden von B-Splines erhaltene neue Geometrie. Das entwickelte System konnte im getesteten Kartenmaterial mehrere Probleme identifizieren.

In diesem Zusammenhang wurden auch Probleme in den Spurbegrenzungen festgestellt. Dabei entstanden insbesondere an Kreuzungen mit bestimmten Nachbarschaftsbeziehungen Inkonsistenzen, die zu problematischen geometrischen Darstellungen führen. Beispielsweise sind die Mittellinien der Spuren in seltenen Fällen nicht innerhalb ihrer zugehörigen Begrenzungen. Diese Fälle können im Anschluss an die Analyse ebenfalls automatisiert erkannt werden. Auf dieser Basis hat Valeo einen Reparatur-Algorithmus erstellt, der durch die Verknüpfung mit vorangegangenen und nachfolgenden Spuren eine neue Spurbegrenzung berechnet und somit zu einer konsistenten Kartendarstellung beiträgt. Diese automatisierte Verbesserung wird in Abbildung 31 dargestellt.

Zusammenfassend hat Valeo in Strategien und Methoden entwickelt, um Fehlermoden in HD-Karten zu erkennen und diese automatisiert zu reparieren, mit dem Ziel, eine konsistente Karte zu erzeugen. Dies ist unerlässlich, um die Anforderungen an die Karte, insbesondere für das Training von KI-basierten Pfadplanern, zu erfüllen.

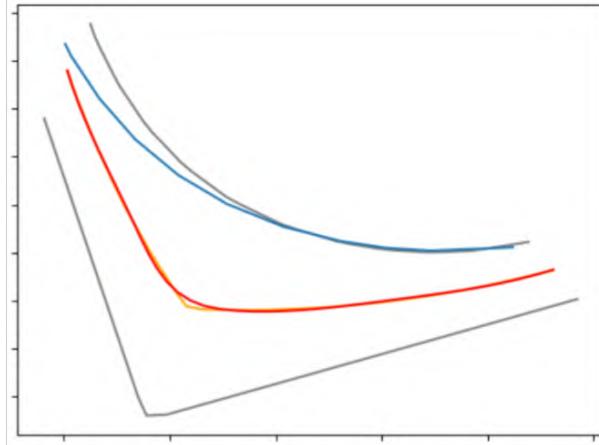


Abbildung 30: Zeigt gefundene Probleme und Korrekturen an den Pfaden eines Spursegments. Die originalen Begrenzungslinien sind als graue Linien eingezeichnet, während der originale Spurpfad als blaue Linie dargestellt ist. Es ist zu sehen, dass der Pfad in der Karte teilweise die Begrenzung überlappt, was beispielsweise für Planungsalgorithmen problematisch sein kann, da diese einen Pfad innerhalb der Fahrspurgrenzen erwarten. Zusätzlich sind der neu generierte Pfad in Orange und ein mittels Splines verfeinerter Pfad in Rot eingezeichnet. Diese neuen Pfade liegen per Definition etwa mittig zwischen den Begrenzungslinien. Weiter ist zu sehen, dass die rote Linie im Verhältnis zur orangefarbenen Linie einen stetigen Verlauf besitzt.

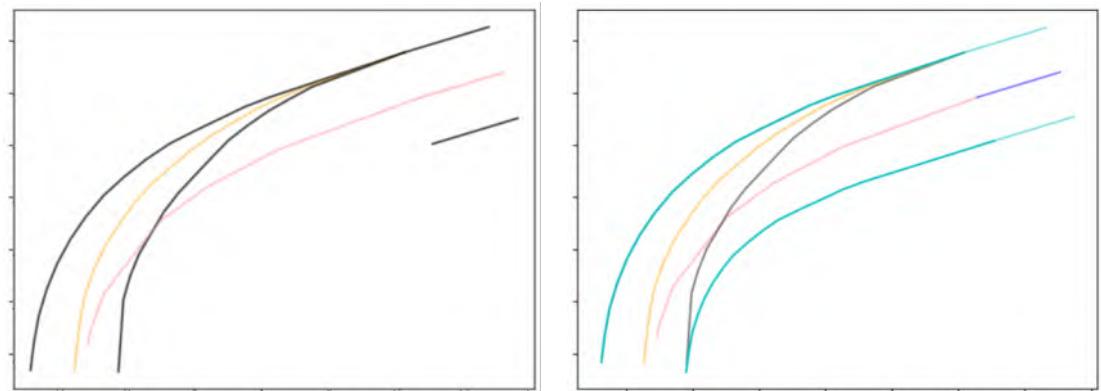


Abbildung 31: Illustriert ein weiteres Problem mit kollabierenden Begrenzungen. In der linken Teilabbildung sind die originalen Begrenzungen als schwarze Linien eingezeichnet. Der Originalpfad ist in Pink dargestellt, während der interpolierte Pfad in Orange gezeigt wird. Es ist klar zu erkennen, dass eine Diskrepanz zwischen Pfad und Begrenzungen besteht. Die rechte Teilabbildung zeigt zusätzlich in Cyan die neuen Begrenzungslinien nach Anwendung der automatisierten Korrektur.

Weiterhin hat Valeo ein Tool zur manuellen Korrektur und Ergänzung von Kontrollelementen wie Zebrastreifen, Haltelinien usw. auf Basis frei verfügbarer Satellitenbilder entwickelt. Diese Informationen werden manuell erfasst, können jedoch in Zukunft als Grundlage für KI-basierte Verfahren zur automatisierten Generierung dieser Informationen dienen. Eine Beispiel-Illustration des Tools wird in Abbildung 32 dargestellt. Das Tool wurde auch für die OpenDrive-Kartendaten des Schwarzen Berges eingesetzt. Beispiele hierfür sind in Abbildung 33 zu sehen.



Abbildung 32: Ansicht des generierten Mapping-Tools. Ein Satellitenbild ist mit Karteninformationen überlagert. Spurbegrenzungen und Pfade sind als semitransparente rote und grüne Linien dargestellt. Des Weiteren werden die extrahierten Begrenzungen der befahrbaren Flächen als blaue Linien eingetragen.



Abbildung 33: Darstellung des Mapping-Tools für den Schwarzen Berg. Hier sind die Straßenverläufe in Rot und Objekte in Blau dargestellt.

1.2.2.4. Aufbau eines Modells für Kartendaten und Sensordaten

Für die Verwendung der Karteninformationen innerhalb des Umfeldmodells musste ein dedizierter Container für diese Informationen entwickelt werden, da Formate wie OpenDrive nicht auf einen effizienten Zugriff der Informationen ausgelegt sind. Weiterhin soll dieser Container eine Korrektur der geometrischen Informationen erlauben und somit die Fusion von Karteninformationen mit den Daten der Fahrzeug-Sensoren ermöglichen. Die Analyse der Kartendaten sowie die Entwicklung und Bewertung mehrerer prototypischer Implementierungen zeigte, dass die funktionalen Anforderungen am zuverlässigsten durch eine fahrspurbasierte Darstellung erfüllt werden können. Insbesondere im Autobahnkontext bietet diese Repräsentation erhebliche Vorteile: Sie ermöglicht eine präzise Definition der „Region of Interest“, unterstützt verbesserte Prädiktionsmodelle für die Bewegungsplanung getrackter Fahrzeuge und erleichtert die Spurzuweisung sowie das darauf aufbauende Clustering der Sensormessungen.

In der Literatur bekannte Methoden zur Darstellung von Spurmarkierungen und Fahrspuren verwenden oft Polylinien oder Polynome. Diese Art der Modellierung hat jedoch entscheidende Nachteile: Polynome können beispielsweise keine starken Kurven darstellen, Koeffizienten sind nicht einfach zu updaten und die konsistente Prädiktion ist komplex, ohne zusätzliche Parameter einzuführen. Des Weiteren können außerhalb ihres definierten Bereichs die Koeffizienten zweier ähnlicher Polynome stark variieren, was Mehrdeutigkeiten der Beschreibung für Teilsegmente erzeugen kann. Polylinien hingegen tragen nur Linieninformationen über Segmente, welche wiederum nicht für eine Schätzung mittels eines Bayes'schen Modells mit kontinuierlicher Ableitung geeignet sind. Sie sind somit beispielsweise nicht für akkurate Prädiktoren von Objekten entlang der Spur geeignet. Allerdings erlaubt eine segment-basierte Darstellung wie in Abbildung 34, wie sie beispielsweise im OpenDrive Format verwendet wird, effiziente, punktbasierte Assoziationsverfahren zu verwenden.

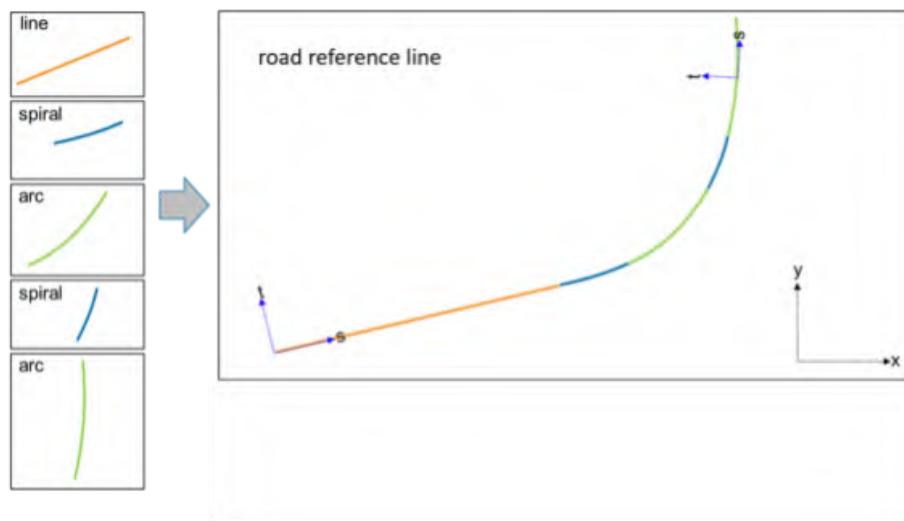


Abbildung 34: Veranschaulichung der Geometry-Typen aus dem OpenDrive Format.

Eine weitere, in der Literatur verwendete Repräsentation von Fahrspuren bzw. Spurmarkierungen sind Splines. Diese werden durch ein Set von 2D-Punkten, die aufeinanderfolgende Segmente mit kontinuierlichen Ableitungen beschreiben, dargestellt. Durch die Basis-Repräsentation mit-

tels 2D-Punkten lassen sich diese einfach prädizieren. Ein Bayes'sches Update-Schema ist in der Literatur im Automotivekontext bekannt [21]. Jedoch sind die Punkte selbst nicht Teil der Linie, was die Darstellung komplizierter macht. Insbesondere ist die Initialisierung neuer Punkte nicht intuitiv.

Diese nachteiligen Eigenschaften lassen sich durch die Verwendung von uniformen *Catmull-Rom Splines* verbessern: Diese besitzen die Eigenschaft, dass ein Segment durch vier Punkte definiert ist, von welchen zwei am Anfang bzw. am Ende des Segments liegen. Entsprechend kann eine glatte Kurve dargestellt werden, welche gleichzeitig eine effiziente Erweiterbarkeit sowie Assoziationsverfahren erlaubt. Catmull-Rom Splines wurden in der Literatur auch für die Modellierung von Fahrspuren eingesetzt [22, 23]. Diese folgen jedoch nicht Bayes' Ansatz, sondern führen eine generelle Optimierung durch.

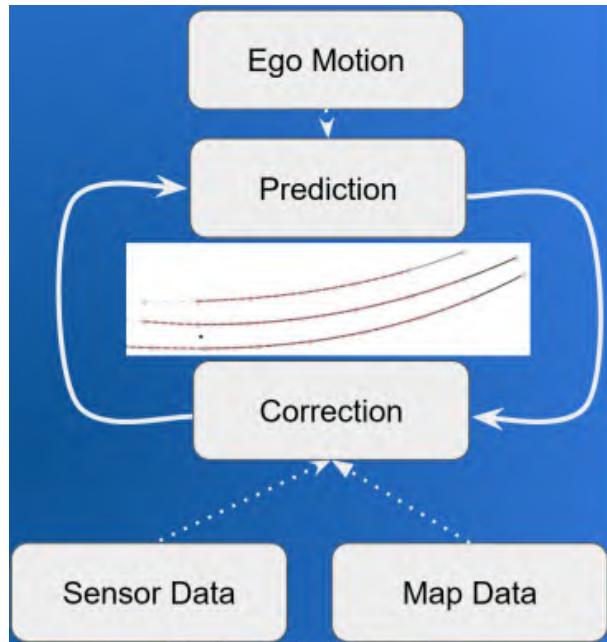


Abbildung 35: Das generelle Updateschema des Fahrspurmodells im Umgebungsmodell. Die getrackten Fahrspuren sind dabei das zentrale zu trackende Modell, welches seine Korrektur durch Sensor und/oder Kartendaten erfährt, wenn sie vorhanden sind und durch die Eigenbewegung des eigenen Fahrzeugs prädiziert werden.

Valeo hat im Rahmen des Projekts ein vollständiges Bayes'sches Modell, das dem Schema in Abbildung 35 entspricht, für Fahrspurmarkierungen basierend auf Catmull-Rom Splines erstellt. Ein Beispiel des Modells auf einem Set von Sensordaten ist in Abbildung 36 zu sehen.

Eine detaillierte Auswertung des entwickelten Modells zeigt ein zumeist wohldefiniertes Verhalten in der Darstellung der Spurmarkierungen. Für die Verwendung in einer Fahrfunktion muss jedoch aus den jeweiligen Spurmarkierungen eine Fahrspur abgeleitet werden, d.h. Eine Spurabschaltung basierend auf den Spurmarkierungen. Dies stellt einen zusätzlichen Rechenaufwand dar, welcher durch einen Umbau des Modells vermieden werden kann: Anstatt der Spurmarkierungen können die Fahrspuren direkt geschätzt werden. Die Breite der Spur wurde als Eigenschaft der Kontrollpunkte betrachtet und ein neues Abbildungsmodell sowie eine angepasste Assoziation aufgebaut. Ein Beispiel des neuen Modells ist in Abbildung 37 zu sehen.

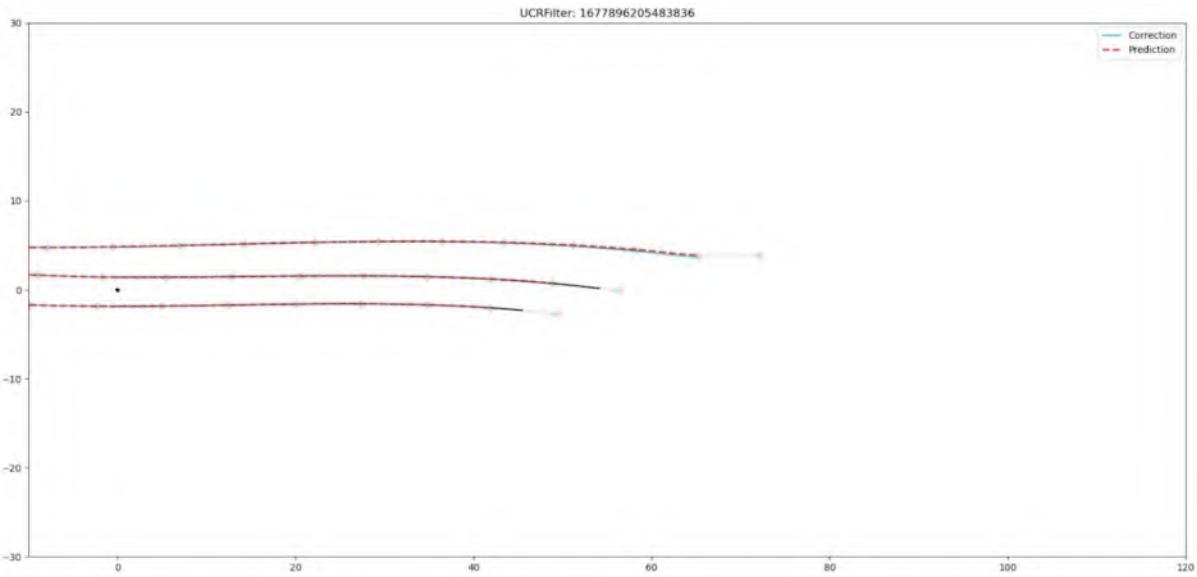


Abbildung 36: Beispieldarstellung von Fahrspurmarkierungen eines Fahrzeugsensors in Schwarz, den prädizieren Linien aus dem letzten Zeitschritt als rote gestrichelte Linien und der Korrektur des aktuellen Zeitschritts als Cyane Linien, welche in diesem Fall stark von den roten und schwarzen Linien überdecken werden.

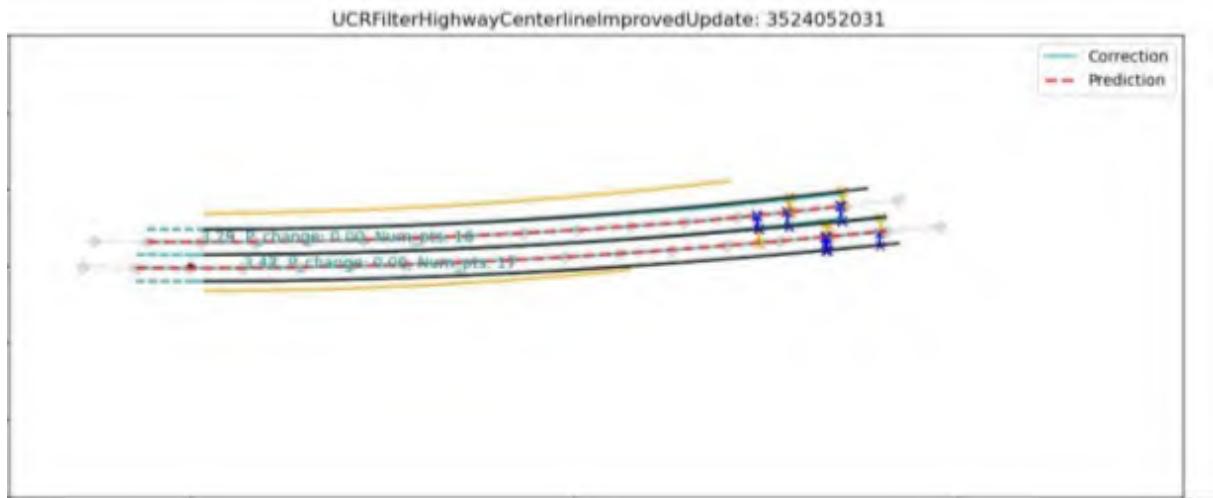


Abbildung 37: Darstellung der getrackten Fahrspuren und der Fahrspurmarkierungen eines Fahrzeugsensors in Schwarz. Die getrackten Mittellinien und die Begrenzungen der Fahrspuren werden nach der Prädiktion als gestrichelte rote Linien und Korrektur als zyane, durchgezogene Linien dargestellt. Dabei wird auch für jede Fahrspur ein Set von Parametern angezeigt. Es handelt sich um die geschätzte Breite, einen Klassifikator Score, der beschreibt, ob die Fahrspur am Ende schließt, und die Anzahl der Punkte, die die Fahrspur beschreiben.

Die Analyse des Modells zeigte im Folgenden Vorteile des so aufgebauten Modells:

- Eine Schätzung der Spurbreite auf Daten nahe dem Sensor führt zu einer konsistenteren Breitenschätzung. Dies ist direkt ersichtlich, da weit entfernte Daten inhärent unsicher-

rer sind. Für eine Fahrfunktion bedeutet diese Verbesserung an Konsistenz ein genaueres Verhalten, insbesondere bei der Schätzung von Spurzuweisungen.

- Die Breite der Fahrspur kann weiterhin ein Indikator für den Typ der aktuellen Operation-Design-Domäne sein. Genauer unterliegen die Fahrspurbreiten von Autobahn, Landstraße oder städtischen Bereich unterschiedliche Richtlinien [24].
- Durch ein konsistentes Tracking der Spurbreite, und die Annahme, dass sich Spurbreiten typischerweise langsam verändern, können Ausreißer im Sensor Input bereits mitigiert werden. Dies stabilisiert insbesondere den Fehlermodus, dass häufige Ausreißer am Ende der Sichtbarkeit Fahrspuren lokal verändern und die Funktion ein Verschwinden der Fahrspur andeuten. Abbildung 38 zeigt ein solches Beispiel. Weiterhin erlaubt dies, falsche Spur-Zusammenschlüsse zu korrigieren, wie in Abbildung 39 dargestellt wird.

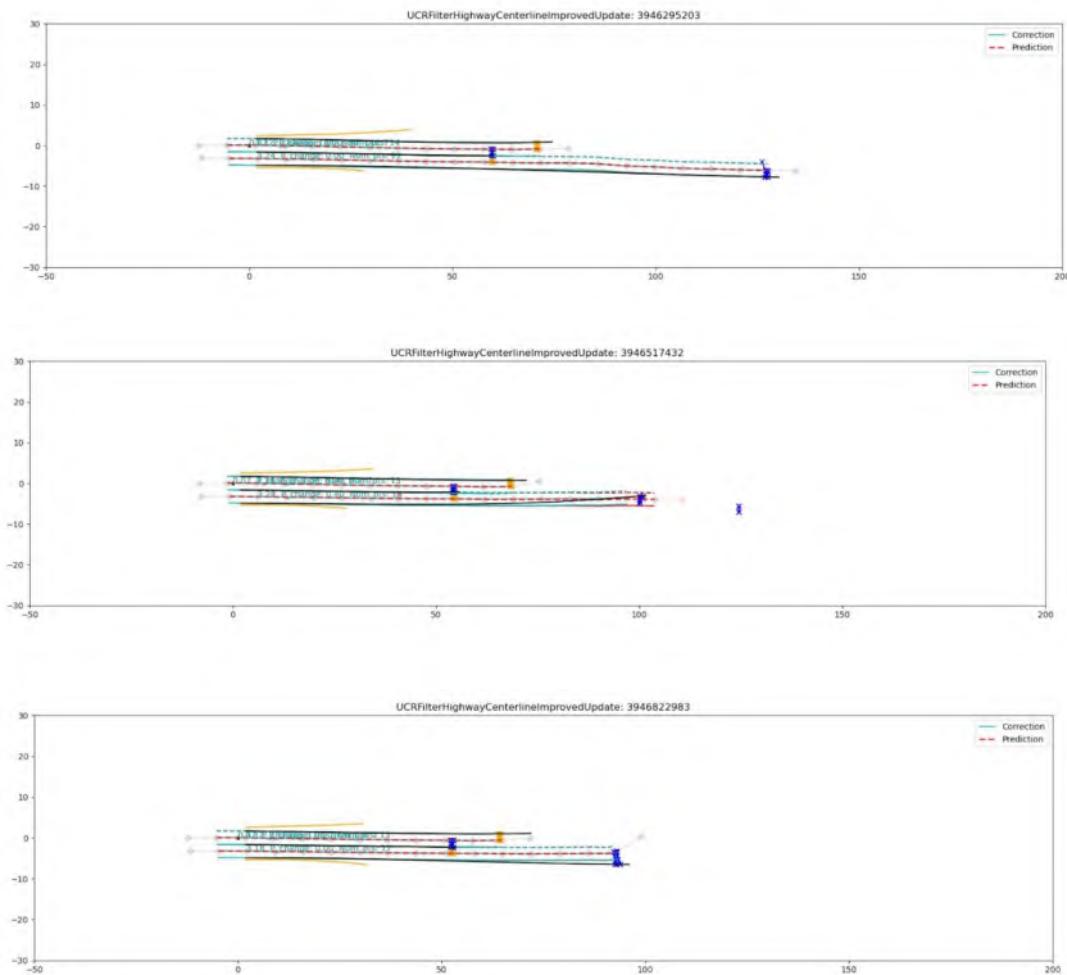


Abbildung 38: Die Abbildung zeigt drei Zeitschritte, die aufeinander folgen. Die zweite Abbildung zeigt dabei Sensordaten, welche eine Krümmung am Ende der Fahrspur implizieren. Das getrackte Modell ist jedoch in der Lage, diesen Fehler zu mitigen und weiterhin eine gerade Linie darzustellen, welche, wie in der 3. Abbildung sichtbar wird, ein Ausreißer war.

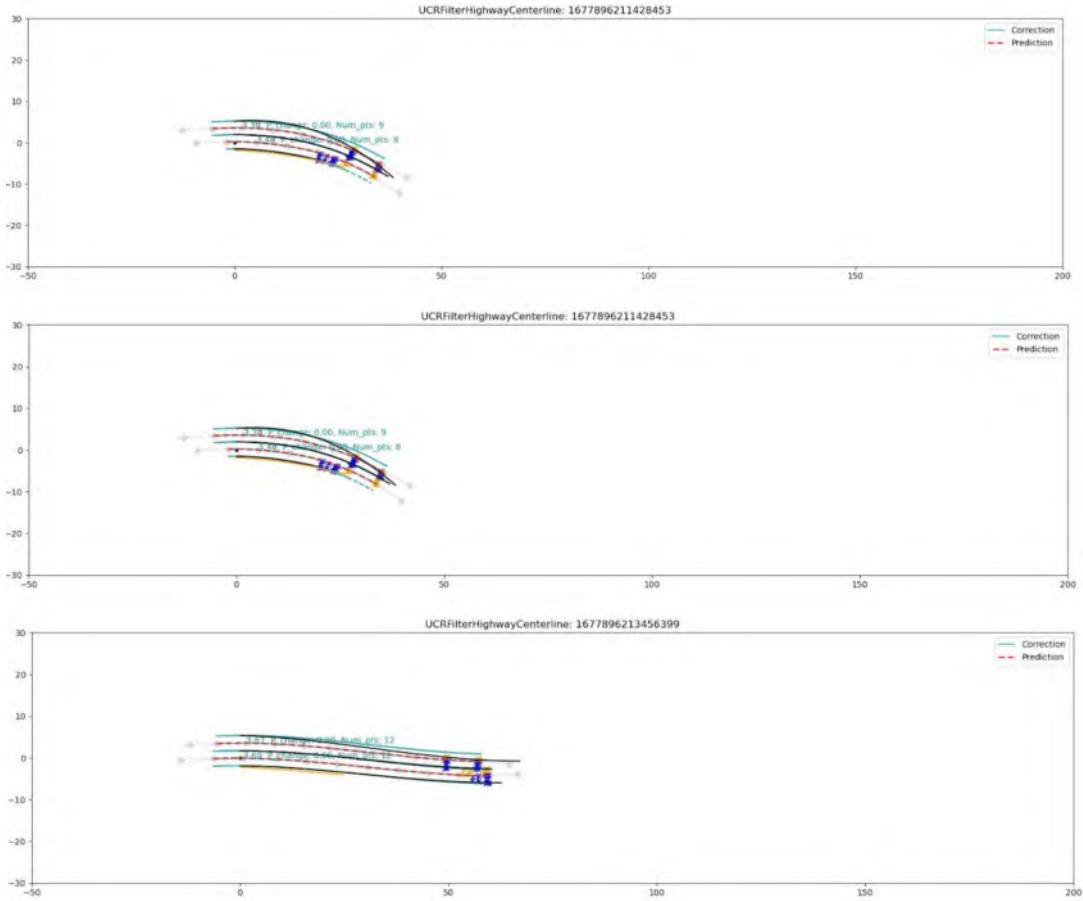


Abbildung 39: Die Abbildung zeigt 3 Zeitschritte, die kurz nacheinander kommen. Die 2. Abbildung zeigt dabei Sensordaten, welche eine Krümmung am Ende der Fahrspur implizieren. Das getrackte Modell ist jedoch in der Lage, diesen Fehler zu mitigieren und weiterhin eine gerade Linie darzustellen, welche, wie in der 3. Abbildung sichtbar wird, ein Ausreißer war.

Die Modellierung der Spurbreiten als langsam veränderliche Größen erfordert allerdings ein explizites Klassifizieren von Spurzusammenschlüssen. Dieser errechnet basierend den Residuen der Geschätzten sowie in den Sensordaten vorhandenen Fahrspuren eine Wahrscheinlichkeit eines Zusammenschlusses. Wird dieser erkannt, wird entsprechend die Geometrie der verschwindenden Spurmarkierung angepasst. Die praktische Umsetzung dieser Anpassung geschieht, indem Updates nur noch mit der schließenden Spurmarkierung durchgeführt werden, oder alternativ indem die Unsicherheit der nicht schließenden Markierung erhöht wird. Abbildung 40 zeigt das Resultat dieses Verfahrens. Ist ein Zusammenschluss jedoch bekannt, kann er auch geometrisch korrekt für einen echten Zusammenschluss der Fahrspuren genutzt werden, wie in Abbildung 41 angegeben.

Neben den bisher aufgeführten Entwicklungen wurden für eine stabile Implementierung folgende weitere programmiertechnische Konzepte ausgebaut. Diese Konzepte führen zu einem neuen Fahrspurmodell, das nach Optimierung eine Laufzeit von etwa einer Millisekunde pro Korrektur und Prädiktion erreicht und wird in Abbildung 42 dargestellt. Das Modell wurde auf typischen drei- bis vierspurigen Autobahnen mit einem relevanten Bereich von -70 bis 200 Metern in Testfahrten evaluiert.

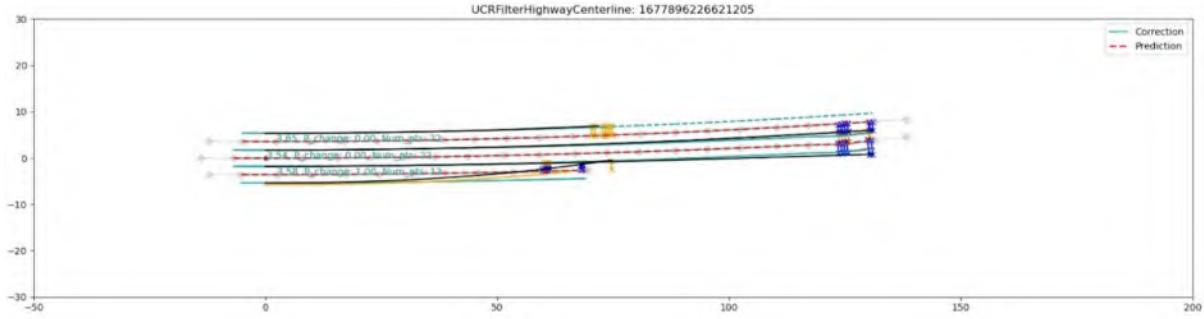


Abbildung 40: Zeigt die Verbesserung der Fahrspurklassifikation. Dabei wird die Fahrspur an der klassifizierten Stelle des Zusammenschlusses beendet. Die unterste Fahrspur endet dabei am Zusammenschluss.

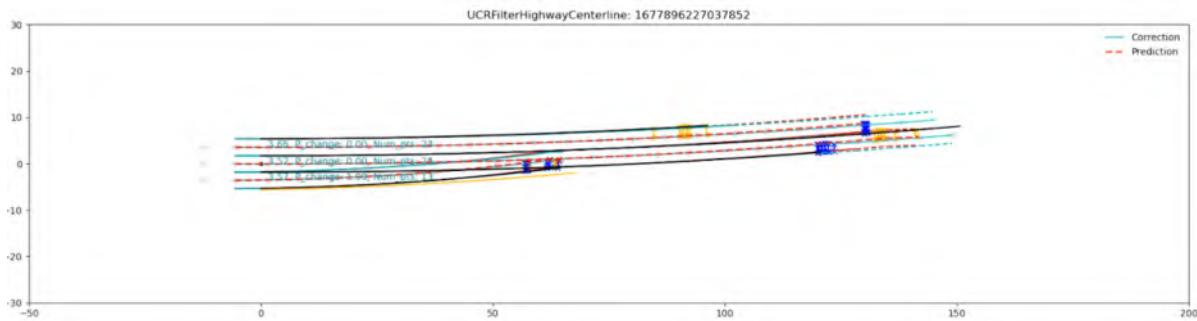


Abbildung 41: Zeigt die Verbesserung der Fahrspurklassifikation und der geometrischen Interpretation, die dabei abgeleitet werden konnte. Dabei wird die Fahrspur an der klassifizierten Stelle des Zusammenschlusses an der zusammenschließenden Geometrie festgehalten und endet auf der benachbarten Fahrspur.

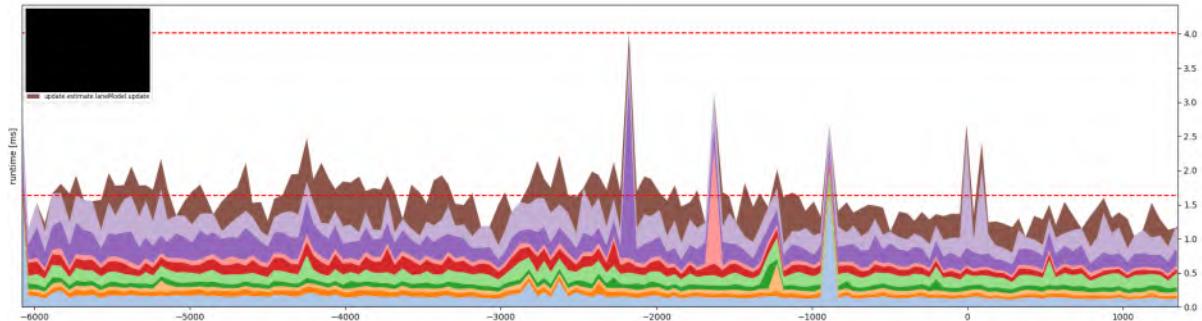


Abbildung 42: Zeigt die Laufzeiten des Umfelds Modells in Millisekunden, speziell ist die Laufzeit des Updates des neu entwickelten Fahrspurmodells zu sehen. Die Namen der anderen Laufzeiten wurden hier aus Datenschutzgründen verschleiert.

Das erstellte Fahrspurmodell steht allen anderen Komponenten im Umfeldmodell sowie den Containern der Eingangsdaten als Zusatzinformation zur Verfügung. Das Fahrspurmodell bietet im Gesamtsystem verschiedene Funktionen an, unter anderem:

- Die Berechnung und Zuweisung von Punkten zu Spuren. Hierunter lassen sich auch Abfragen erstellen, ob ein Punkt innerhalb der Fahrspuren oder außerhalb liegt. Die Berechnung erfolgt über ein Newton-Raphson-Verfahren.

- Berechnung der erwarteten Spurkrümmung (Curvature) oder des Gierwinkels (Yaw) an einem angefragten Punkt.

Grundsätzlich lassen sich die verfügbaren Informationen bei Bedarf erweitern. Es ist jedoch hervorzuheben, dass alle nötigen Informationen für die im OKULAR-Projekt geplanten Zielfunktionen zur Verfügung stehen. Beispielsweise ist die Punktzuweisung bereits ein zusätzliches Clustering der Daten. Abbildung 43 zeigt Karteninformationen und die erfassten Spuren des Modells in einem gemeinsamen Koordinatensystem.

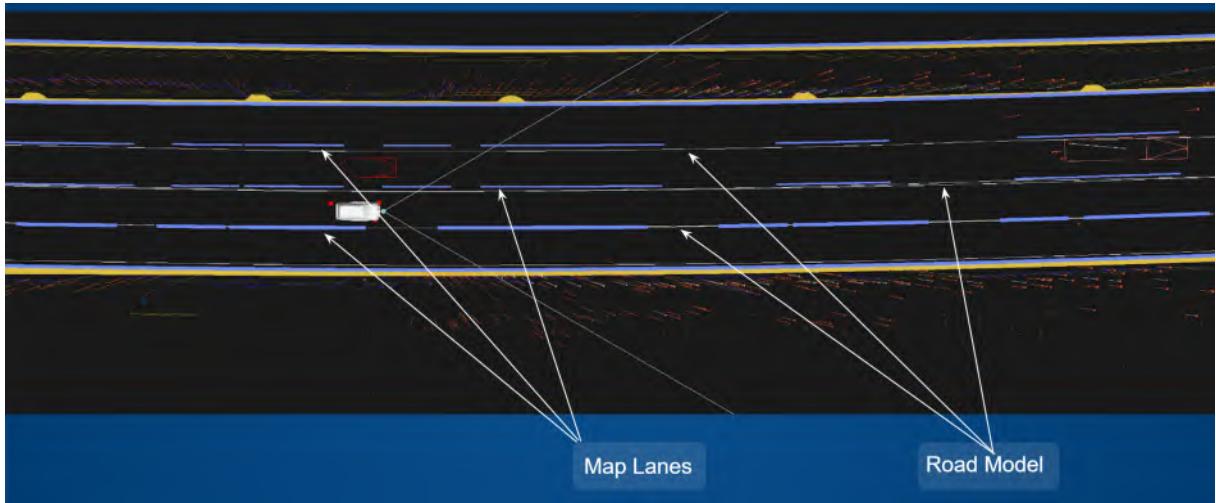


Abbildung 43: Darstellung von Informationen aus der Karte der A81 und dem entwickelten Spurmodell in der im OKULAR-Projekt entwickelten Visualisierung.

Laterales Alignment

Um die Fusion von LiDAR-Punktwolke und Spurinformationen zu gewährleisten, werden aus der LiDAR-Punktwolke typischerweise zuerst Spurinformationen gewonnen. Diese erzeugen ein kurzreichweites Bild der Umgebung des Fahrzeugs. Im Folgenden verwenden wir dieselbe Art Information, um die Konzepte für das laterale Alignment zu erarbeiten. Die Information stammt jedoch von einer Automotive Kamera, da die Verfügbarkeit des eigentlich zur Verwendung geplanten, hochauflösten Valeo Scala 3 nicht zur Verfügung stand.

Um ein globales Bild der Karte mit dem lokalen Bild der Fahrzeugsensorik zu vereinigen, wird die Assoziation aus dem Unterabschnitt „Aufbau eines Modells zur kartengestützten Definition einer dynamischen Region of Interest“ (S. 52ff.) verwendet, um eine Art der groben Lokalisierung zu erhalten. Diese fusioniert das aktuelle Straßensegment mit den globalen Kartendaten basierend auf einer groben Positionierung in der Karte. Für die Fusion von Spurinformationen der Fahrzeugsensorik und Spurinformation einer hochauflösenden Karte zur redundanten Spurerkennung wurden zuerst Referenzdaten von Spurinformationen in einem Bereich gesammelt, in welchem Karteninformationen existieren. Ein Beispiel von Kamera-Fahrspurinformationen und Kartendaten ist in Abbildung 44 illustriert. Dabei wurden auch Daten mit einer IMU eingefahren, bei der eine geringere Präzision der GPS-Daten vorliegt, um auch eine verschlechterte Situation prüfen zu können.



Abbildung 44: Die Abbildung zeigt ein Beispiel der Kartendaten und Kamera-Spurmarkierungen aus der Vogelperspektive. Die orange eingefärbten Linien sind dabei die Detektion der Kamera.

Die geteilten Informationen sind bei dieser Fusion Geometrien, die zwischen dem lokalen Fahrzeugsystem und dem System der Karte geteilt werden. In unserem Fall sind dies Informationen über Spuren und Straßenbegrenzungen, welche von einem LiDAR-Sensor erzeugt werden können, in unserem Fall aber von einem Kamerasytem stammen. Dabei kann das Catmull-Rom Spline Modell verwendet werden, um die lokalen Spurinformationen zu beschreiben.

Diese Information soll nun zur Verbesserung der Transformation zwischen den Systemen verwendet werden. Die erste Anwendung ist dabei die Transformation der Spurmarkierungen aus der Karte in Fahrzeugkoordinaten und vice versa. Dabei kann das Fahrzeug lateral verschoben werden, um die Spurmarkierungen überein zu bringen. Im Endeffekt kann das erste und zweite Moment einer Assoziation zur Verbesserung verwendet werden. Dies erlaubt es, eine einfache Optimierungsfunktion aufzustellen. Wir rechnen in diesem Fall aus dem Startpunkt der Kamera Linien und der Ableitung an diesem Punkt eine Rotation und eine laterale Verschiebung aus, die verwendet werden kann, um die Fahrzeug-Pose relativ zur Karte zu verbessern. Das Prinzip wird in Abbildung 45 für die Spurmarkierungen, in denen sich das eigene Fahrzeug befindet, aufgezeigt. Die Abbildung wirft jedoch auch ein weiteres Problem auf, das es zu beachten gilt. In diesem Fall befindet sich das Fahrzeug noch innerhalb der korrekten Fahrspur, jedoch ist dies nicht zwangsläufig korrekt, da die initiale Pose auch auf einer anderen Spur, wenn nicht sogar außerhalb dieser, liegen kann und eine starke Rotation zwischen den Systemen auftreten könnte. Dies passiert schnell bei Verlust des Satellitensignals, wie es bei Tunnelfahrten vorkommt. Dabei ist das Matching der lokalen Informationen komplizierter, da die Anzahl der erkannten Spuren oft auf kein konstantes Set limitiert ist und nicht immer alle Spurmarkierungen und Straßenenden korrekt erkannt werden.

Das Grundproblem stellt sich als Assoziationsproblem aller Spuren der Fahrzeugsensorik auf alle Spuren der Karte dar, jedoch können einige geometrische Einschränkungen abgeleitet werden, solange Landstraßen- oder Autobahn Szenarien vorliegen:

- Die Spuren können als geordnet betrachtet werden und die möglichen Assoziationen können nur innerhalb der Ordnung existieren. Des Weiteren kann das Kreuzen von Fahrspuren in

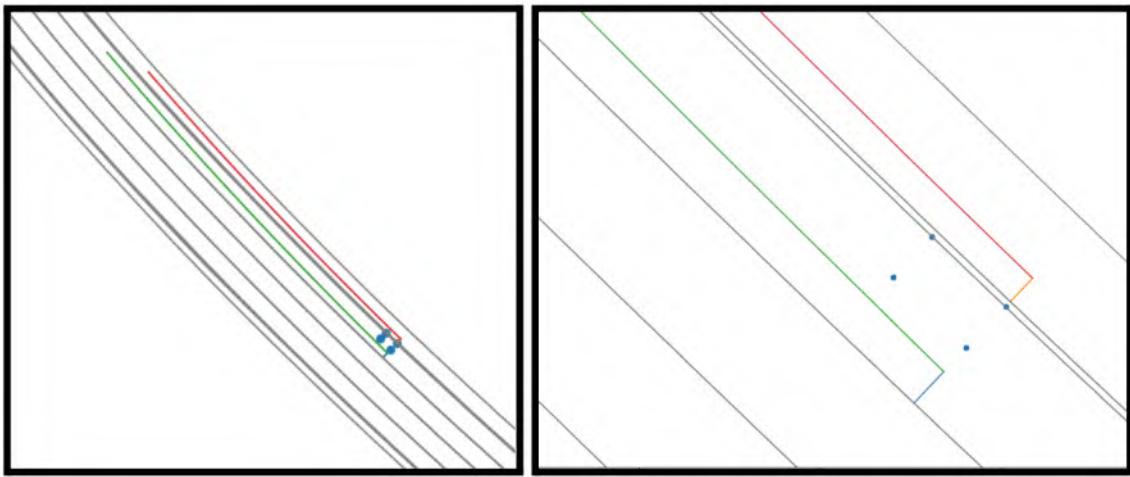


Abbildung 45: Beispiel der einfachen Assoziation zwischen einem Subset der Kamera-Linien und den Spurmarkierungen der Karte. Die Reifen des Ego-Fahrzeugs sind als Referenz mit blauen Punkten gekennzeichnet, die Karten-Spurmarkierungen als graue Linien und die Kamera-Linien der Host-Lane sind als grüne bzw. rote Linie eingezeichnet. Zusätzlich wurde die Assoziation der Kamera auf Host-Linien an deren Startpunkt durch eine blaue bzw. eine orange Linie hervorgehoben.

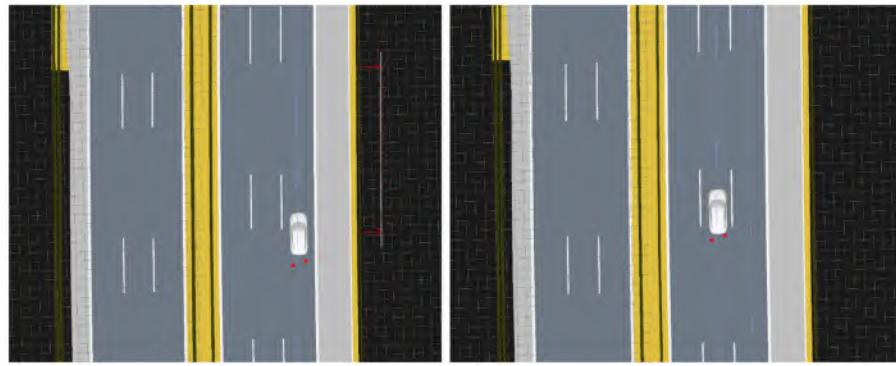
diesen Szenarien ausgeschlossen werden. Somit kann eine lineare Anzahl an Kombinationen verwendet werden.

- Solange die Straßenränder existieren und vom Sensorsystem erfasst werden, können diese als grobe Lokalisierung verwendet werden und der Raum der möglichen Assoziationen kann limitiert werden.
- Die Orientierung der Fahrspuren entspricht annähernd der Referenzlinie.

Damit kann ein limitiertes Set an Assoziationen verwendet werden und das Optimum gewählt werden. Das daraufhin gestaltete verfahren führt nun folgende Schritte aus, um die Posenschätzung zu verbessern:

- Optimierung der, auf dem Fahrzeug-Yaw basierend, Winkeldifferenz der Kamera, den Spuren und der Referenzlinie.
- Optimierung der lateralen Position basierend auf Straßenbegrenzungen, falls diese vorhanden sind.
- Feinabstimmung der lateralen Position basierend auf der Assoziation der Kamera Spurmarkierungen innerhalb der Straße.

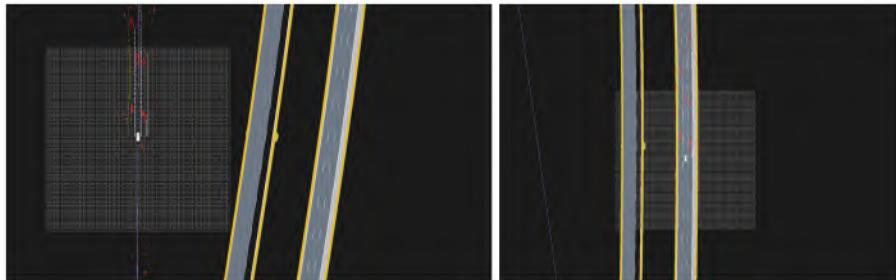
Dieses Verfahren wurde auf Fahrten mit Karte und extremem GPS-Verhalten getestet. In diesem Fall wurden Tunnelfahrten mit Satellitensignalausfall untersucht. Ein Set von verbesserten Positionsschätzungen durch das Verfahren kann in Abbildung 46 eingesehen werden.



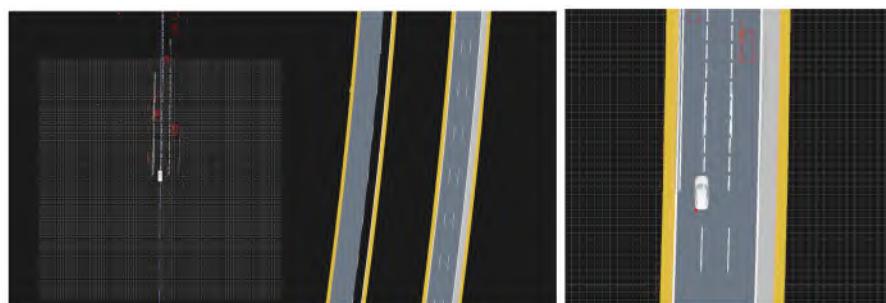
(a) Szenario 1.



(b) Szenario 2.



(c) Szenario 3.



(d) Szenario 4.

Abbildung 46: Die Szenarien zeigen das reine GPS-Mapping auf der linken und die verbesserte Lösung auf der rechten Seite. Von oben nach unten werden die Szenarien komplexer. Szenario 1 zeigt ein Szenario auf der Autobahn, bei dem ein lateraler Fehler vorliegt. In Szenario 1 wurde im ersten Bild durch rote Pfeile der Fehler der Leitplanke markiert. Szenario 2 zeigt ein Szenario am Anfang eines Tunnels, bei dem ein sehr hoher lateraler Fehler vorliegt und Szenario 3 zeigt einen Extremfall, bei dem sowohl ein großer lateraler als auch ein großer Orientierungsfehler auftreten. Szenario 4 zeigt einen Fall, bei dem zusätzlich ein Spurwechsel durchgeführt wird.

Entwicklung einer kartengestützten Bodenerkennung in Punktwolkensensoren

Für die Entwicklung der kartengestützten Bodenerkennung in Punktwolkensensoren wurden einige Vorabuntersuchungen auf statischen Setups durchgeführt. Im Fahrzeug selbst wurde hingegen ein einfacher Abgleich der Höhe der Karte verwandt. Dabei ist das Ziel, durch gutes Alignment von Karten und Sensordaten Punkte nahe dem Boden der Karte direkt als solche zu klassifizieren. Im System des Fahrzeugs selbst konnte der Boden mit der Karte weiter analysiert werden. Ein signifikanter Problemfall beim Alignment der Kartendaten wurde aufgezeigt, welcher in Abbildung 47 dargestellt wird.

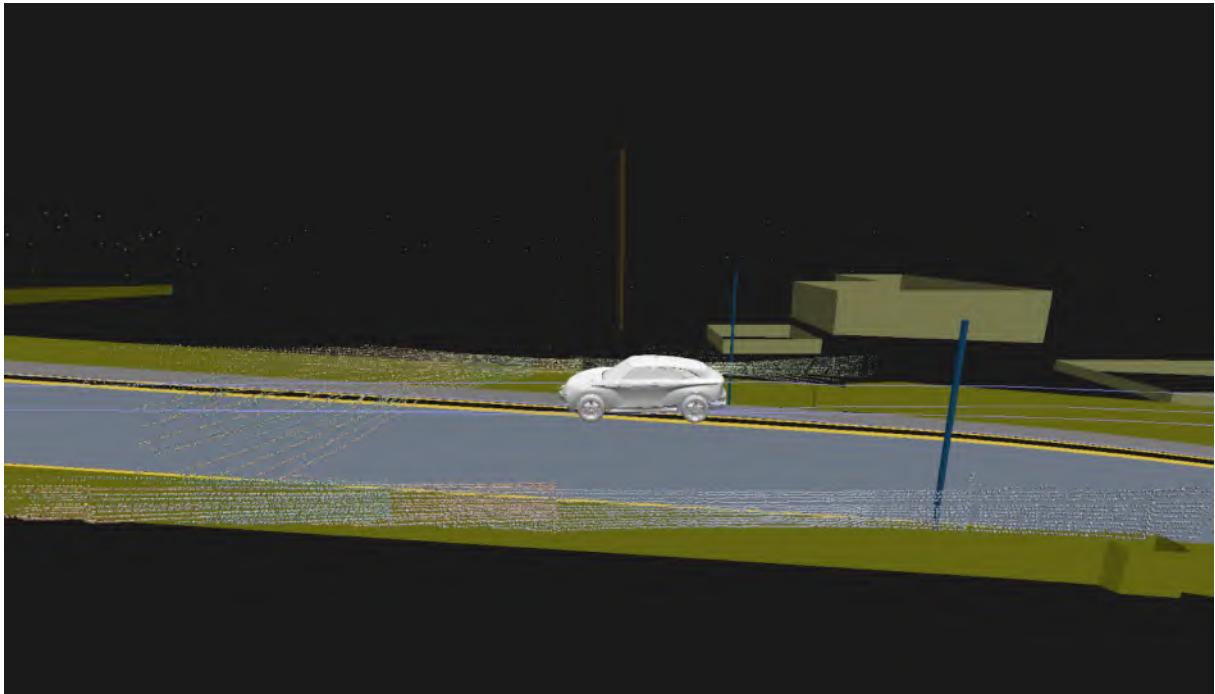


Abbildung 47: Beispieldarstellung der GPS-Projektion in Kartenkoordinaten. Zu sehen sind das Ego-Fahrzeug, die dazugehörigen Sensordaten, im Speziellen die LiDAR-Punktwolke verschiedener Sensoren, und die Karte. Die Projektion ist dabei deutlich fehlerhaft. Das Fahrzeug schwiebt über der Straße, wie an der linken Leitplanke deutlich zu sehen ist. Es ist auch ein Winkelfehler zwischen den LiDAR-Punkten und der Kartendarstellung ersichtlich, speziell im Pitch des Fahrzeugs.

Zum Einen ist die Höhe beim Mapping der GPS-Koordinaten einer fahrzeuginnenen IMU nicht akkurat, zum Anderen beinhaltet das Mapping keine Ausrichtungskorrektur mit dem Boden der HD-Karte. Dies sorgt dafür, dass die Koordinatensysteme von Sensor und Karte sowohl in der Z-Koordinate verschoben sind, als auch, dass es einen Roll- und Pitch-Fehler in der Transformation zwischen Karte und Fahrzeugkoordinatensystem und damit einhergehend zwischen Sensorinformation und Karte gibt.

Die Lösung dieses Problems ist für die generelle Fusion von Kartendaten und Sensorinformation notwendig. Um ein sinnvolles Alignment zu erreichen, nutzen wir hier eine Projektion der Z-Koordinate auf die Karte, dies eliminiert den Höhenfehler. Danach passen wir die Rotation auf der Karte an. Um es zu erreichen, wurden mehrere Schätzverfahren getestet. Das finale Resultat nutzt die bekannten Positionen des Fahrzeugs, welche den Boden berühren, somit die

Positionen der Reifen, und wir projizieren diese auf die Straße. Dies generiert vier Berührpunkte auf der Straße, welche über welche eine Ebene geschätzt und woraus eine Rotationsmatrix errechnet werden kann. Dies resultiert in einer deutlich verbesserten Darstellung der Kartendaten in Sensorkoordinaten.

Durch das Verfahren wird sowohl die Visualisierung verbessert und die visuelle semantische Interpretation der Daten erleichtert, als auch ein Konzept zur Verbesserung der Projektion zwischen Ego- und Kartenkoordinaten aufgestellt, das auch in der Datenfusion zum Einsatz kommen könnte. Die Koordinatensysteme folgen hierbei ISO 8855. Beispiele der Projektion, Korrekturen und die einzelnen Schritte sind in Abbildung 48 zu finden. Zusammengefasst wurde ein verbessertes Alignment von Karten und Sensordaten erstellt, welches die Bodenklassifikation zu einem einfachen Höhenvergleich macht.

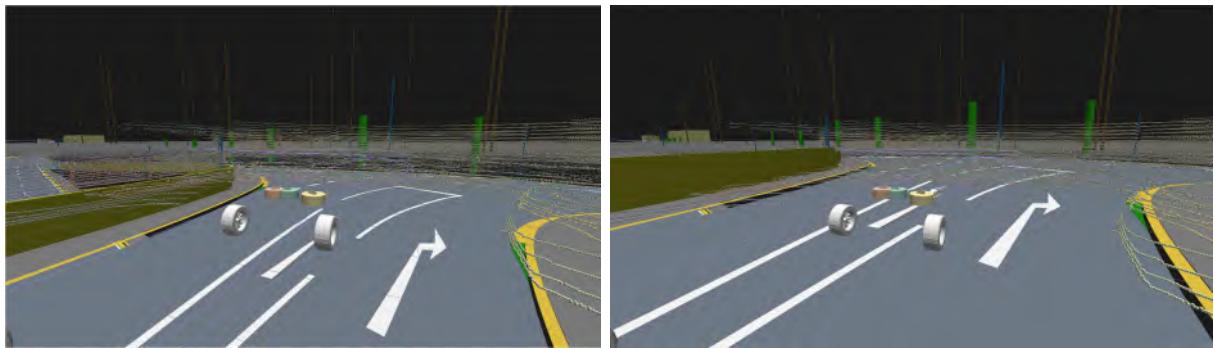


Abbildung 48: Vergleich der Projektionen in hochauflöster Karte. Speziell werden die Vorderreifen des projizierten Fahrzeugs in der Szene dargestellt, die für das beschriebene Verfahren genutzt werden, um die Ebene zu schätzen, aus welcher die gewünschte Rotationskorrektur geschätzt wird. Die linke Abbildung zeigt die Daten mit reiner GPS-Transformation, das 2. Bild zeigt die korrigierten Räder nach der Korrektur durch das vorgeschlagene Verfahren. Zu beachten ist nun auch, dass ein laterales Offset der Punkte des Bürgersteigs an der rechten Seite des Bildes zu erkennen ist und somit die Interpretation der Daten verbessert wird.

Aufbau eines Modells zur kartengestützten Definition einer dynamischen Region of Interest

Zur Entwicklung eines kartenbasierten dynamischen Beobachtungsbereichs („Region of Interest“) wurden eingehende Untersuchungen basierend auf OpenDrive-Karten durchgeführt. Für die Verarbeitung im Fahrzeug muss die Karte an der entsprechenden Position geladen werden. Dies erfordert die Identifikation des jeweiligen Straßensegments, sowie die Durchsuchung der Karte nach den benachbarten Elementen. Hierfür wurde eine distanzbasierte Suche nach Segmenten zu einer gegebenen GPS-Position entwickelt. Dieser agiert auf einer Graph-Darstellung der Karte. Der Graph selbst wird dabei auf dem OpenDrive-Linking aufgebaut, und stellt die Verbindungen zwischen Straßensegmenten dar: Jedes Straßensegment ist ein Knoten des Graphen, während Verbindungen zwischen den Straßensegmenten als Kanten dargestellt sind.

Auf diesem Graphen wurde eine Breitensuche implementiert, um dynamisch eine Untermenge der benötigten Pfade für die „Region of Interest“ zu generieren. Die Breitensuche nimmt die Kosten der Traversierung einer Kante annahmegemäß als 1 an und wird ungerichtet betrachtet,

um auch eingehende Straßensegmente zu berücksichtigen. Eine Darstellung dieses Graphen wird in Abbildung 49 gezeigt und dem entsprechenden Bereich in Google Maps gegenübergestellt. Ein Beispiel für das Laden dieser Pfade relativ zum Fahrzeug ist ferner in Abbildung 50 dargestellt.

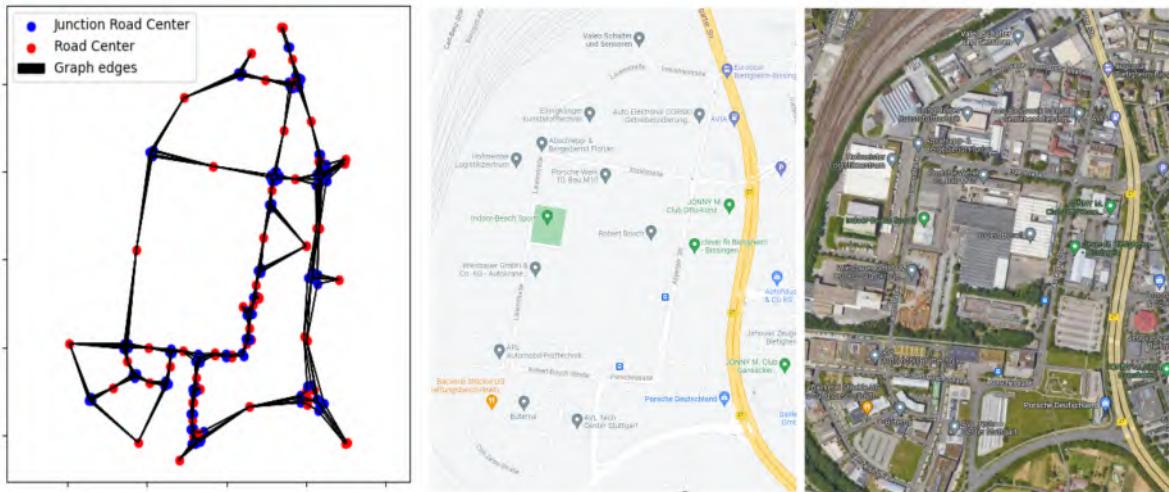


Abbildung 49: Beispieldarstellung eines Straßengraphen einer OpenDrive-Karte des Industriegebiets am Valeo-Standort in Bietigheim-Bissingen sowie dem zugehörigen Ausschnitt aus Google Maps mit Map- und Satellitenlayer. Die Punkte in der ersten Unterabbildung zeigen die Knoten des Graphen, welche die Zentralpunkte der Straßensegmente darstellen. Die Farbe zeigt dabei, ob die Straße Teil einer Kreuzung ist. Die Verbindungslien symbolisieren die Straßen, welche die Knoten verbinden.

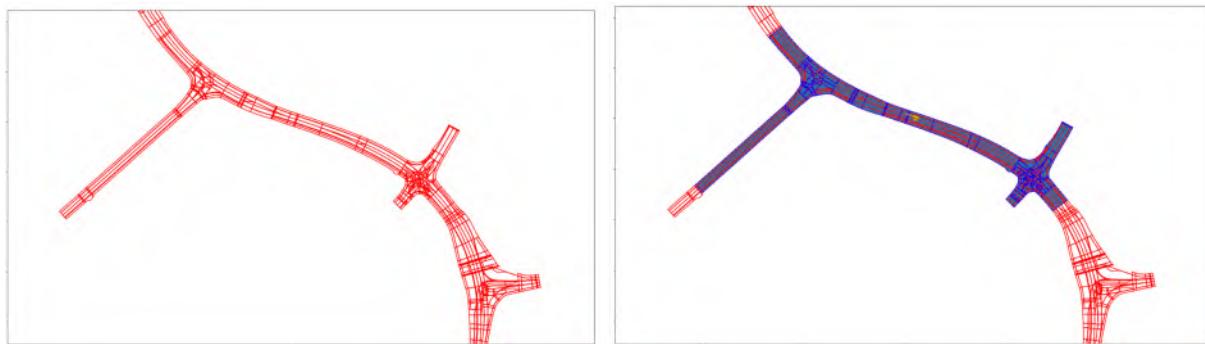


Abbildung 50: Ausschnitt der als Polygone dargestellten Kartensegmente und die positionsbasierte Extraktion von nahen Segmenten. Die erste Abbildung zeigt die Polygone der OpenDrive-Karte in einem Ausschnitt als rote Konturen. Die zweite Abbildung zeigt die relativ zur als gelber Punkt dargestellten Fahrzeugposition geladenen Polygone als blau gefüllte Flächen an, wobei die nicht geladenen Elemente ungefüllt bleiben.

Weiterhin wurde basierend auf diesem Polygon ein effizientes Verfahren entwickelt, das angefragte Positionen als *innerhalb des Polygons* und *außerhalb des Polygons* klassifiziert. Hiermit lassen sich gegebenenfalls falsch getrackte, nicht relevante Objekte außerhalb der Region of Interest klassifizieren und entfernen. Für eine effizientere Abfrage in komplexen Fahrbahn-Geometrien wurde die Konvertierung des Fahrbahn-Graphen in eine Rasterkarte der Region of

Interest aufgebaut. Die Rasterkarte wurde prototypisch implementiert und enthält in vorgegebener Auflösung die Zustände *belegt* und *unbelegt*, wie in Abbildung 51 dargestellt wird.

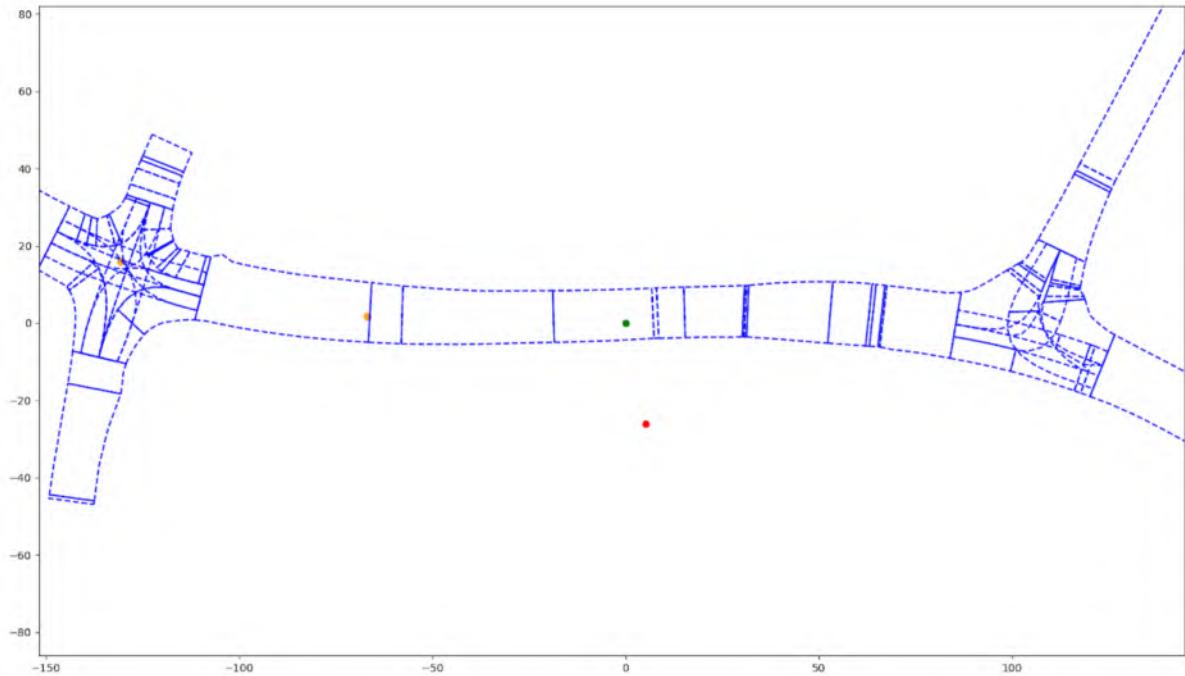


Abbildung 51: Die Abbildung zeigt Detektionen als Punktobjekte und die Klassifikationen dieser. Der grüne Punkt referenziert das Eigenfahrzeug, die orangefarbenen Punkte referenziert die Fahrzeuge innerhalb der Region of Interest, und der rote Punkt zeigt ein Objekt außerhalb der Region of Interest an.

Der zuvor beschriebene Prototyp des Graphen wurde nach detaillierter Analyse wie folgt verbessert:

- In der ursprünglichen Implementierung wurden die Straßen als Knoten und die Verbindungen zwischen ihnen als Kanten betrachtet. Diese Interpretation wurde vertauscht, so dass den Längen der Kanten eine physikalische Bedeutung in Form der Länge der jeweiligen Straße zugewiesen werden konnte.
- Straßen wurden in zwei gerichtete Kanten mit jeweils zwei Knoten an beiden Enden unterteilt, abhängig davon, ob die Straßenrichtungen valide nutzbare bzw. befahrbare Elemente beinhalten. Somit ist ein gerichteter Graph entstanden.
- Die Knoten sind dabei stets über den mittleren Endpunkt aller in ihm endenden Straßen definiert. Speziell werden Knoten über die IDs ihrer verbundenen OpenDrive-Elemente beschrieben. Ein Knoten ist somit durch ein Tupel der IDs des eingehenden und des ausgehenden Elements definiert. Hierbei wird von einem Element gesprochen, da ein Knoten die ID einer Kreuzung anstelle der Straßenelemente und deren IDs verwendet, sofern er mehrere Elemente miteinander verbindet.
- Die Straßen innerhalb einer Kreuzung verbinden somit immer zwei Knoten miteinander, die sich durch die ID der Kreuzung sowie die eingehende und ausgehende Straße definieren.

Die Illustration der neuen Graphen erfolgt in Abbildung 52. Sie zeigt ein Beispiel einer komplexen zerlegten Kreiselstruktur sowie eine in zwei gerichtete Kanten unterteilte Straße.

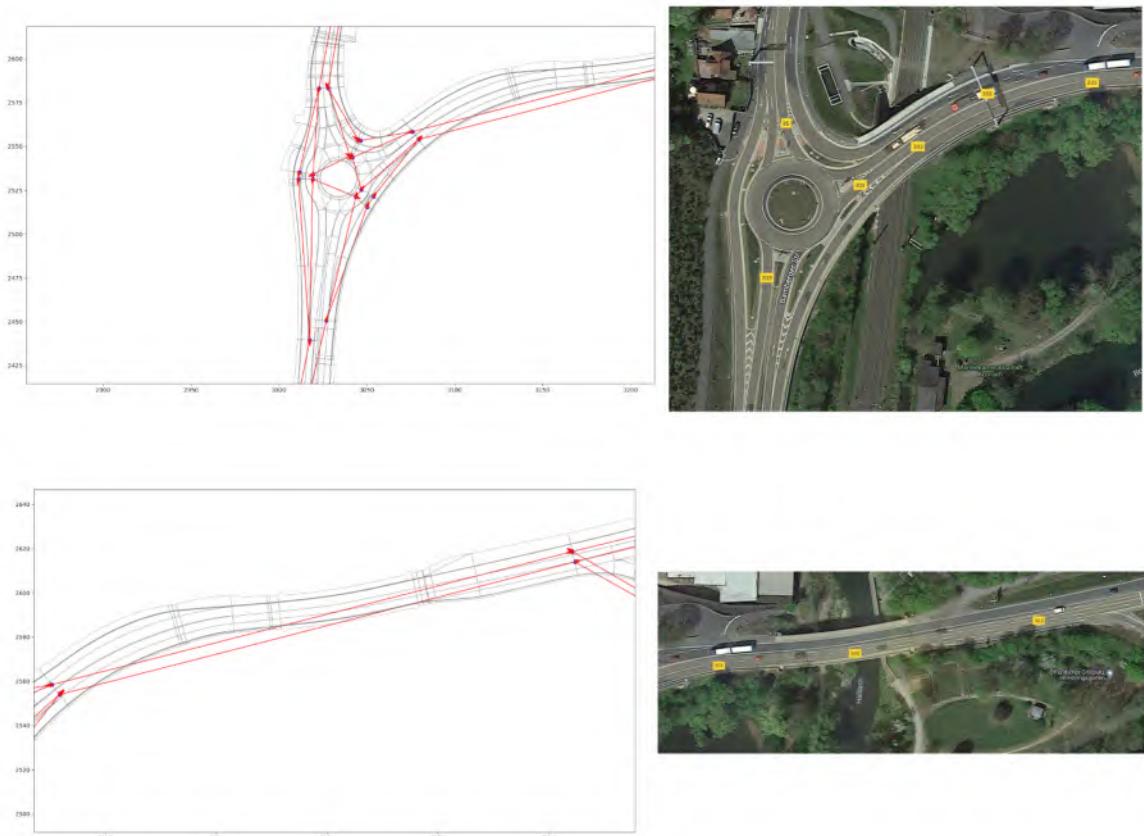


Abbildung 52: Die linken Abbildungen zeigen die zugrundeliegende Geometrie der Straßen aus der HD-Karte in Grau, die Knoten des Graphen in Blau und die Kanten in Rot. Die rechten Abbildungen zeigen den zugehörigen Ausschnitt aus Google Maps. Die erste Abbildung zeigt ein komplexes System eines Kreisels mit Seitenstraßen und illustriert, wie Straßen mit nur einer validen Fahrtrichtung durch eine Kante repräsentiert werden. Die zweite Abbildung zeigt, wie eine Straße, die durch eine Geometrie beschrieben wird, durch zwei Kanten repräsentiert wird.

Der gerichtete Graph bietet unter anderem die Möglichkeit der Fahrplanung, wodurch beispielsweise die relevanten Kartenelemente im Voraus geladen und schneller bereitgestellt werden können. Zur Realisierung dieser Funktion wurden zwei Shortest-Path-Algorithmen implementiert: Der Algorithmus von Dijkstra als Greedy-Algorithmus und A* als informierter Algorithmus. Grundsätzlich stellt A* eine Erweiterung von Dijkstras Algorithmus dar, die davon ausgeht, dass zwischen den Knoten eine Heuristik erstellt werden kann, die ein unteres Limit der Distanz zwischen den Knoten beschreibt. In der neuen Graphenimplementierung wird dies einfach durch die euklidische Distanz zwischen den Knoten definiert. Mittels der Heuristik werden die Pfadkosten der Traversierung abgeschätzt und Kanten, die in die generelle Richtung des Zielknotens weisen, zuerst gewählt. Ein Beispiel für den Unterschied in der Traversierung zwischen den beiden Algorithmen ist in Abbildung 53 dargestellt.

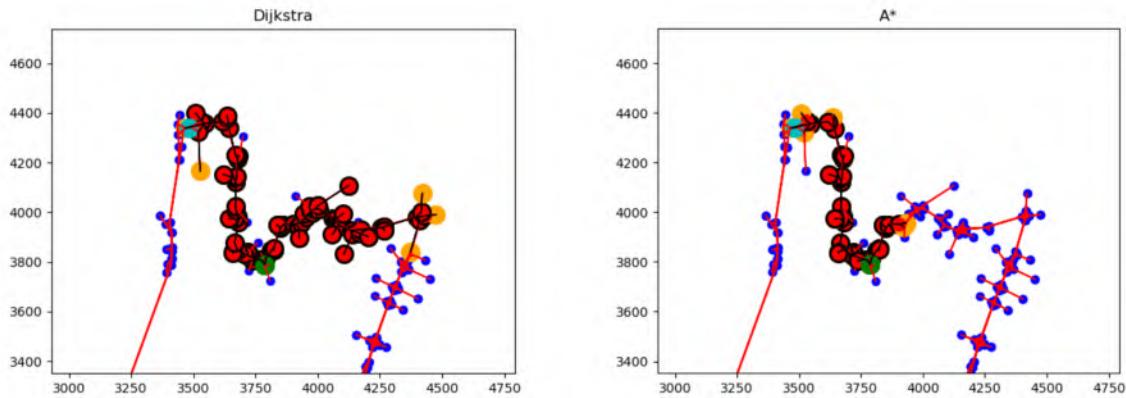


Abbildung 53: Die Abbildung zeigt den Unterschied zwischen dem Dijkstra- und A*-Algorithmus auf dem implementierten Graphen der Karte. Der Graph selbst ist durch rote Kanten und blaue Punkte für die Knoten dargestellt. Der Startknoten des jeweiligen Suchalgorithmus ist als grüner Kreis gekennzeichnet und der Endknoten als Cyaner Kreis. Alle besuchten Knoten der Suchalgorithmen werden durch große rote Kreise mit schwarzem Rand symbolisiert, und alle weiteren Knoten, die in der Warteschlange der Algorithmen liegen, sind als orangene Punkte eingetragen. Es ist klar erkennbar, dass der A*-Algorithmus durch seine gerichtete Suche deutlich weniger Knoten besucht hat als Dijkstras Algorithmus.

Für die Verwendung der Graphenkarte ist es erforderlich, die Fahrbahn, auf der sich das Fahrzeug aktuell befindet, zu bestimmen. Diese initiale Lokalisierung erfolgte auf Basis der aktuellen GPS-Position. Es wurden verschiedene Verfahren über Vergleiche, beispielsweise mit Samplepunkten, geprüft, am Ende wurde für die initiale Lokalisierung jedoch auf das entwickelte Catmull-Rom-Spline-Modell zurückgegriffen: Dies reduziert die nötigen Vergleiche und entsprechend die Laufzeit. Dadurch ist eine laufzeiteffiziente Überprüfung möglich, ob ein Datenpunkt innerhalb einer gültigen Fahrspur liegt. Dies erweist sich insbesondere in Autobahn-Szenarien als vorteilhaft, da die Straßengeometrie dort sehr übersichtlich ist: Fahrzeuge können eine Autobahn lediglich an Ein- und Ausfahrten erreichen oder verlassen.

Zusammenfassend wurde ein Modell der Region of Interest erstellt und als Bestandteil des Fahrspurmodells in das Umfeldmodell integriert. Seine Nutzung wurde aufgrund der kartenspezifischen Einschränkungen jedoch nur aktiv für Autobahnen eingesetzt.

Kartengestützte Auswahl von Bewegungsmodellen sowie multimodale Prädiktion von Objekten anhand von Spurinformationen

Im Rahmen der Arbeiten zur kartengestützten Auswahl von Bewegungsmodellen sowie zur multimodalen Prädiktion von Objekten auf Basis von Spurinformationen wurden grundlegende Konzepte entwickelt.

Es ist vorgesehen, die positionellen Informationen getrackter Objekte relativ zur Fahrbahn zu nutzen, um die generelle Prädiktion dieser Objekte mit den zusätzlichen Informationen der Karte zu verknüpfen. Hierbei sollen zusätzliche Track-Modi bzw. Hypothesen entlang der möglichen Fahrspuren des Fahrzeugs generiert werden, wie in Abbildung 54 dargestellt. Der Grad

der Komplexität dieser Bewegungen kann im typischen Trackingverfahren nicht berücksichtigt werden, da die Zusatzinformationen der Karte die Spurführung definieren und eine sehr große Menge potenzieller Bewegungen möglich ist, welche eine nicht handhabbare Anzahl an Hypothesen erfordern würde.

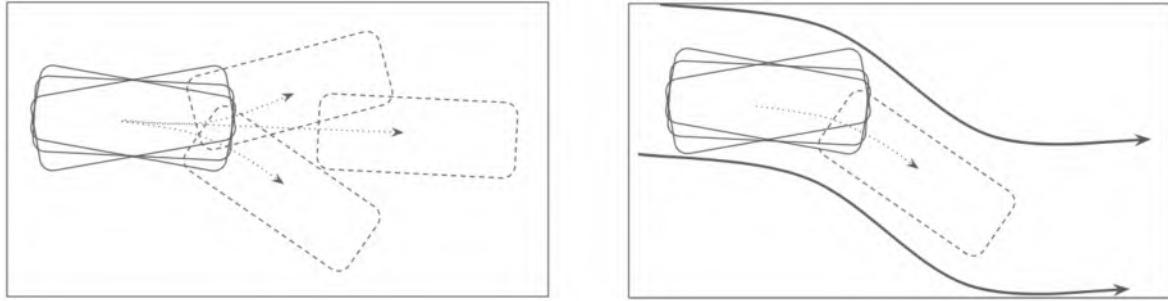


Abbildung 54: Darstellung des Konzepts zur Nutzung der Spurinformationen zur Verbesserung von Bewegungsmodellen. Die linke Abbildung zeigt potenzielle Bewegungen (gestrichelte Boxen), die ein Set von Hypothesen (durchgezogene Boxen) zu einem Zeitpunkt tätigen kann. Die rechte Abbildung zeigt die Spurbasierte Bewegung, die angenommen basierend auf der Karte hinzugefügt werden soll.

Die Lösung dieser Aufgabe konnte durch die entwickelte Catmul-Rom-Spline-Darstellung erreicht werden. Ein Objekt kann einer Spur zugewiesen werden, und die aktuelle Curvature kann effizient abgefragt werden. Zur Fusion der Karteninformation mit den Sensordaten können verschiedene Strategien verwendet werden, welche im Folgenden aufgelistet sind:

- Im ersten Ansatz wird der Winkel der Spur naiv entweder vor oder nach dem Update eines Tracks festgesetzt.
- Im zweiten Ansatz wird die Orientierung als direkte Messung interpretiert, die mit einer Unsicherheit in die Update-Gleichung des Ziels hinzugefügt wird.
- Der dritte Ansatz erzeugt eine zusätzliche Korrektur, welche in einem multimodalen Filter als unterschiedliche Mode desselben Tracks interpretiert wird, wobei das Framework diese dann konsistent verarbeiten kann.

Diese Ansätze führen zu grundsätzlich stabilen Trajektorien. Ein besonders hervorzuhebender Anwendungsfall, bei dem die Kartendaten eine entscheidende Rolle spielten, war der Umgang mit dünnen Radardaten. Dies tritt typischerweise in komplexen Verkehrssituationen oder bei Objekten am Rand des Erfassungsbereichs auf. In solchen Fällen führt die Nutzung der Kartendaten zu einer deutlichen Verbesserung der Orientierung (Lage und Ausrichtung) der geschätzten Objekte. Die geometrischen Informationen und die Kontextualisierung aus der Karte helfen dem Schätzer, die unsicheren oder unvollständigen Radarsignaturen korrekt zu interpretieren und somit eine robustere und präzisere Schätzung der Objektorientierung zu liefern. Das Resultat kann exemplarisch in Abbildung Abbildung 55 eingesehen werden.

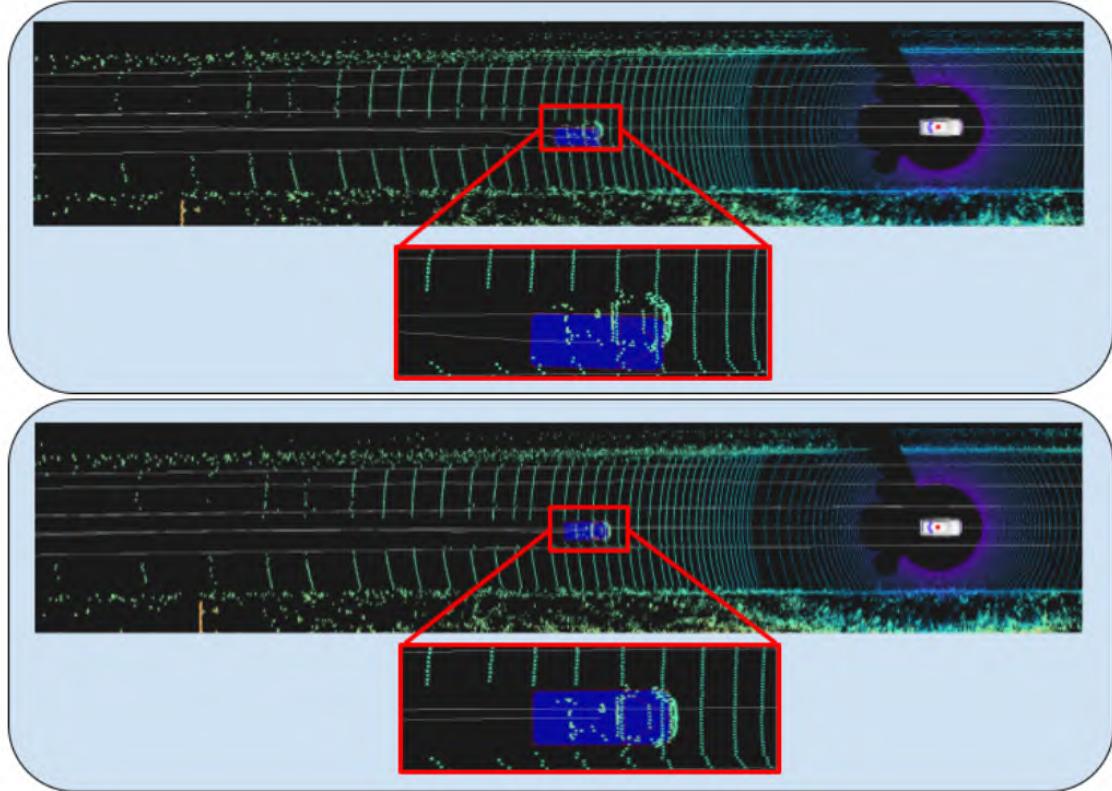


Abbildung 55: Illustration der Verbesserung der Trajektorien einzelner Ziele eines Radarsystems mit Referenzdaten eines Laserscanners. Das erste Bild und der zugehörige Zoom zeigen ein erfasstes Zielfahrzeug hinter dem Hostfahrzeug als blaue Box mit roter Umrandung und seine Historie als weiße Polylinie, die rein auf Radardaten erfasst wurde. Dabei ist zu erkennen, dass das Ziel einen Positionsfehler und einen Winkelversatz im Gegensatz zu den Referenz-Lidarpunkten aufweist. Das zweite Bild zeigt dieselbe Szene, hierbei wurde jedoch die Spurinformation in die Korrektur der Zielschätzung aufgenommen. Hier ist kein Winkelfehler und auch kein Positionsfehler erkennbar. Zudem ist die Historie nun deutlich stabiler.

1.2.3. DLR

1.2.3.1. Aufbau und Erweiterung der Versuchsträger

Ausgangspunkt ist ein bestehender Versuchsträger, siehe Abbildung 56, mit Sensorik, Rechen-einheiten und eigenen Automationsframework [15]. Verfahren zur Manöverplanung sind unter [25] beschrieben. Die für Anbindung der Automation erfolgt bei diesem Fahrzeug über die ACC-Schnittstelle und ist für den öffentlichen Verkehr zugelassen. Im weiteren Projektverlauf wurde die Sensorik projektunabhängig erweitert (u.a. Ouster OS2 LiDAR) sowie ein weiteres Fahrzeug (Mercedes EQV mit mehreren LiDAR-Sensoren) in Betrieb genommen. Weiterer Ausgangspunkt sind Fahrzeuganhänger als größere mobile Messtation (siehe Abbildung 3 rechts) sowie mit den Versuchen zum Projektende eine handelsübliche Kameradrohne (DJI Mini 4 Pro). Für die Durch-führung der Projektversuche wurden hardwareseitig einige Erweiterungen vorgenommen:

- Ausrüstung eines Servers mit neuer GPU zur Datenauswertung und für das Training von Modellen für KI-basierte Mustererkennungsverfahren,

- Ausrüsten des weiteren Fahrzeugs mit Kameras und LiDAR auf dem Dach, inklusive witterungsbeständigen Gehäusen, siehe Abbildung 57,
- Erstellung einer Hardware zur hochgenauen Zeitsynchronisierung (Trigger) zwischen Kamera(s) und LiDAR sowie zur Synchronisierung der Triggerimpulse mit dem PPS-Signal des GNSS, siehe Abbildung 58, sowie Ko-Kalibrierung der Sensoren zueinander, siehe Abbildung 59,
- Beschaffung eines größeren Stativs zur Montage von LiDAR und weiteren Sensoren sowie GNSS-synchronisierter Referenzuhr und Kommunikationshardware, und damit Aufbau einer mobilen Road Site Unit zur Referenzdatengewinnung (siehe Abbildung 73 links).



Abbildung 56: DLR-Forschungsfahrzeug (VW Passat) für das Automatisierte Fahren.

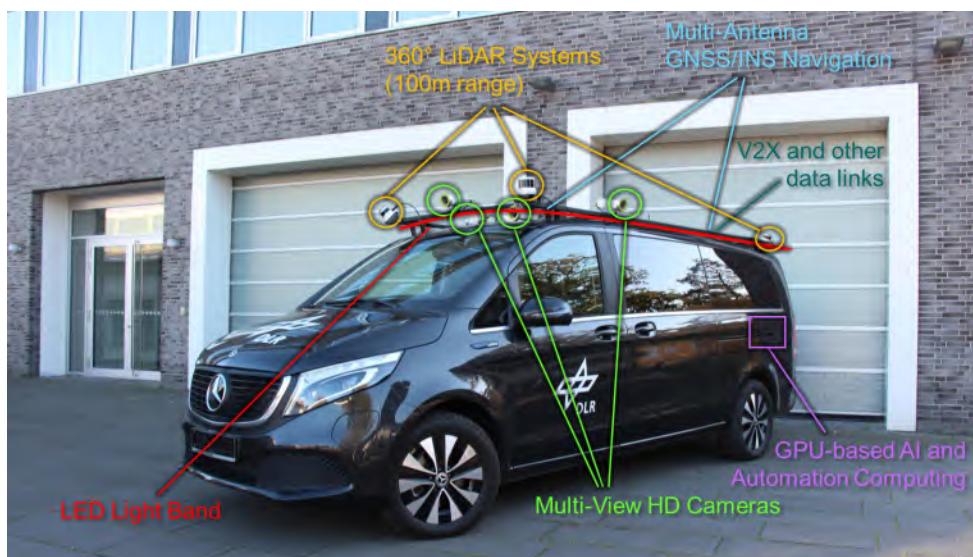


Abbildung 57: DLR-Forschungsfahrzeug (Mercedes EQV) für erweiterte Messdatenaufnahmen.

Zudem wurde die Entwicklung einer Software vorangetrieben, welche zur automatischen Anonymisierung von Sensordaten dient. Dies ermöglicht datenschutzkonforme Aufnahmen im öffentlichen Raum, insbesondere bei Kamerabildern. Da Kamerabildern im Projekt nur eine untergeordnete Rolle spielen, wurde auch untersucht, inwieweit eine Datenschutzbetrachtung für LiDAR-Punktwolken erforderlich ist. Hier kamen wir zum Ergebnis, dass in den LiDAR-Punktwolken bei den verwendeten Konfigurationen keine personenbezogenen Daten wie Kfz-Kennzeichen oder Gesichter identifizierbar sind.

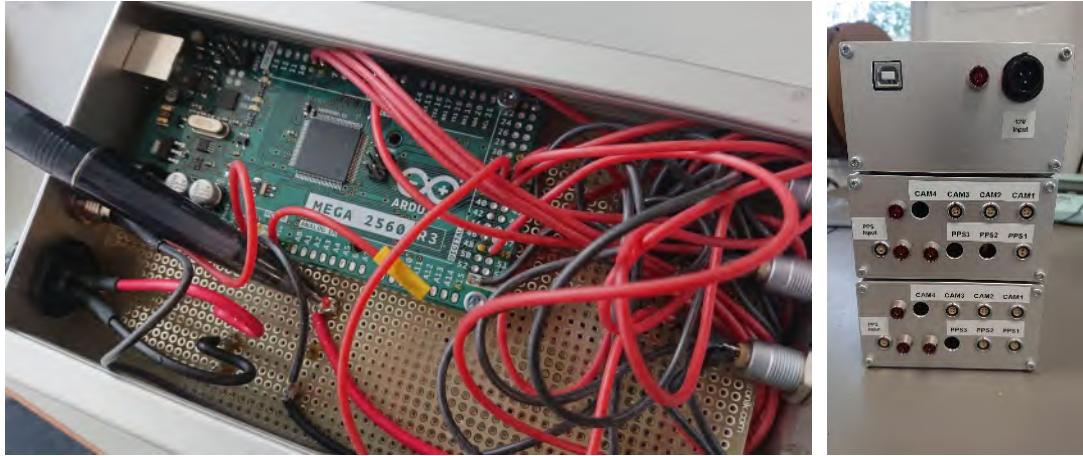


Abbildung 58: Hardware zur Synchronisierung von GNSS, LiDAR und Kamerasensoren.

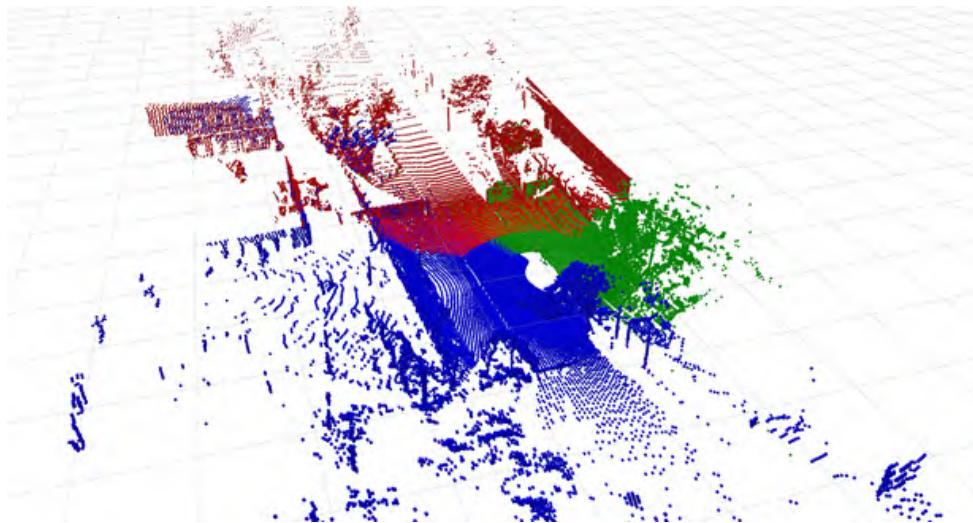


Abbildung 59: Zusammengesetzte Punktwolke aus drei am Fahrzeug montierten LiDAR-Sensoren. Die Farbe repräsentiert die Zugehörigkeit zu je einem Sensor.

1.2.3.2. Spezifikation und Umsetzung der HD-Umgebungskartierung

In Abstimmung mit iMAR Navigation und dem Unterauftragnehmer 3D Mapping GmbH erfolgte die Spezifikation der Datenaufnahmen im Stadtgebiet Braunschweig. Im Februar 2024 erfolgte die Befahrung mit dem Messfahrzeug der 3D Mapping GmbH sowie eine nachfolgende Befahrung mit den eigenen Versuchsträgern zur Gewinnung von Daten im gleichen Zeitraum.

Abbildung 60 zeigt die kartierten Fahrstreifen. Nach Sichtung der prozessierten Daten erfolgten weitere Iterationsschritte zur Fehlerbehebung und Optimierung der Datenqualität. Neben den dargestellten Fahrstreifen sind in den Karten weitere verkehrliche Objekte, Annotationen der Verkehrsflächen (z.B. Fußweg, Radweg, Straßenbahn) sowie Gebäudeinformationen enthalten, siehe Abbildungen 61 und 62. Weitere Details sind den Publikationen [11, 12] zu entnehmen.



Abbildung 60: Visualisierung der kartierten Fahrstreifen im Bereich des Stadtquartiers Schwarzer Berg, Hamburger Straße und Haltestelle am Stadion in Braunschweig (Hintergrund Luftbildkarte: (c) Stadt Braunschweig, 2020).

Mit der Befahrung durch die eigenen Fahrzeuge sind im gleichen Verkehrsraum Messdaten erhoben worden. Aus diesen Daten wurden ebenfalls Punktfolkenkarten erzeugt, welche sich für verschiedene Zwecke nutzen lassen. Abbildung 63 zeigt einen Ausschnitt bei Anwendung der LiDAR-Lokalisierung in einer erneuten Befahrung.



Abbildung 61: Ausschnitt aus der Punktwolkenkartierung (links), Gebäudekartierung (rechts) mit semantischer Unterscheidung, hier zwischen Gebäude und kleineren Elementen wie Carports.



Abbildung 62: Semantische Segmentierung von Verkehrsflächen, hier Fußwege (gelb), Radwege (blau) und nicht befahrbaren Straßenbahnschienen (rot). Ergebnisse vor (links) und nach einem Nachbereitungsschritt (rechts).

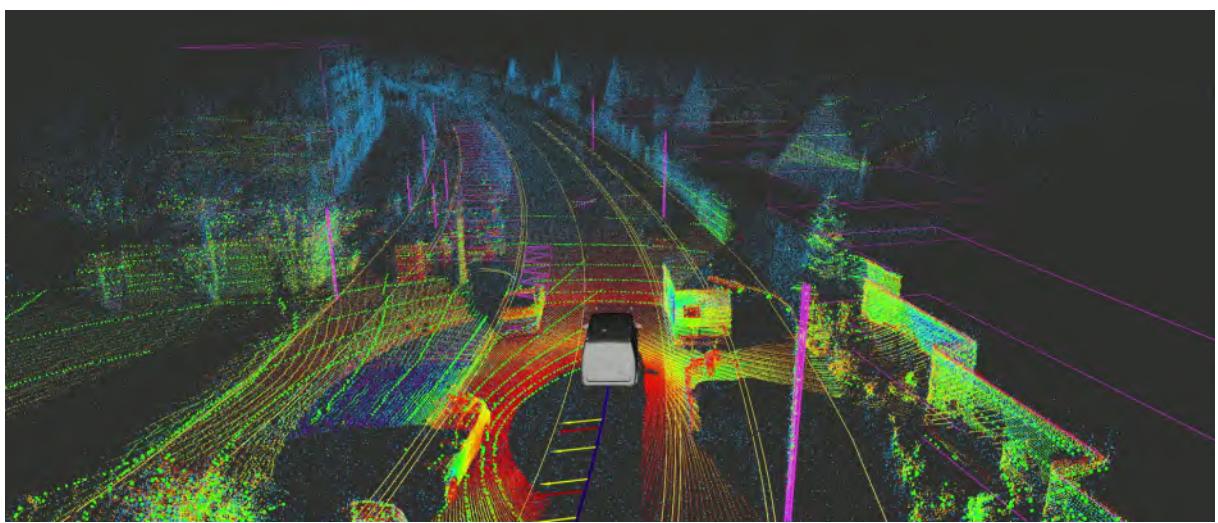


Abbildung 63: Visualisierung der mit dem eigenen Fahrzeug (grau) eingemessenen Punktwolkenkarte (blaue Punkte) und einer anschließende Befahrung zur LiDAR-basierten Lokalisierung (Abgleich LiDAR mit Karte: grüne Punkte). Die Darstellung enthält weitere Kartenmerkmale wie OpenDrive-Geometrien und Objektkanten.

1.2.3.3. LiDAR-Navigation mit Punktwolkenkarten

Ausgangspunkt für die Weiterentwicklung sind LiDAR-gestützte SLAM-Verfahren, wie sie in vorausgehenden Projekten wie *KoMo:Dnext* implementiert und demonstriert wurden [26, 27]. Bei der Datenfusion werden die Eingangsdaten aus GNSS-Position, INS und LiDAR-Positionierung (SLAM) kombiniert und anhand der jeweils mitbestimmten Genauigkeiten gewichtet. Herausfordernd sind Positionssprünge bei wechselnden oder fehlerhaft geschätzten Genauigkeiten der Eingangsdaten, sowie LiDAR-Positionsfehler im Realverkehr aufgrund der Charakteristik der Messdaten. Hier zeigt sich insbesondere, dass die in vielen SLAM-Verfahren vorgesehene Erkennung dynamischer Objekte anhand der Bewegungen nicht ausreichend ist. Im realen Verkehr sind dies insbesondere andere Fahrzeuge im näheren Umfeld, die sich z.B. an Kreuzungen nicht bewegen und damit nicht gefiltert werden. Daher werden, wie im folgenden Abschnitt 1.2.3.4 beschrieben, Entwicklungen im Bereich der semantischen Segmentierung zur Vorfilterung der Eingangsdaten vorangetrieben. Bei der Datenfusion zur Positionierung bzw. Navigation betrachtet dieser Abschnitt daher die Verarbeitung semantisch vorgefilterter Daten bzw. Verbesserungen abseits der semantischen Segmentierung.

Für die Relativortung wurde eine LiDAR-basierte Lokalisierungsmethode integriert, die auf einer 3D-Erweiterung des Normal-Distribution-Transformation (NDT)-Verfahrens aus [28] basiert. Darüber hinaus wird das Verfahren mit einer GNSS-basierten Lokalisierung fusioniert, um so eine georeferenzierte Lokalisierung zu erhalten (siehe Abbildung 64), auch wenn GNSS während der Fahrt ungenau ist (zum Beispiel aufgrund von Signalabschattung, schlechtem Wetter oder in Tunnels). Wir haben bei Mehrfachfahrten und Übereinanderlegen der Messdaten systematische Fehler in den Karten beobachten können, die durch systematische Positionsfehler aus der GNSS-Lösung bedingt sind. Dagegen haben wir ein iteratives Verfahren getestet, das eine neue Karte erstellt – unter Nutzung einer fusionierten Lokalisierungslösung auf Basis der GNSS-Lokalisierungsdaten und einer LiDAR-basierten Lokalisierung mit Hilfe der zuvor erstellten Karte. Wir konnten beobachten, dass mit diesem Verfahren z.B. Dopplungen von Landmarken entfernt werden konnten. Wir haben das Verfahren in die Fahrzeuge integriert und sind anschließend erfolgreich mit diesem Verfahren autonom durch Braunschweig gefahren.



Abbildung 64: Ausschnitt der georeferenzierten LiDAR-Karte zur LiDAR-basierten Lokalisierung. Rote und blaue Punkte aus verschiedenen Einzelfahrten.

Durch Einbinden georeferenzierter Punktwolkenkarten kann die Relativierung in eine Absolutierung überführt werden. Zwar existieren derartige Karten in unbekannten Gebieten bzw. in einem forschungstypischen SLAM-Szenario nicht, allerdings lassen sich derartige Karten durch GNSS-gestützte Befahrung erstellen und in späteren Fahrten weiternutzen. Wesentlicher Aspekt ist zur Erstellung georeferenzierter Karten ist die Mehrfachbefahrung einer zu kartierenden Region. Die Fusion der Daten aus mehreren Messfahrten ermöglicht eine Kompensation des GNSS-Positionsrauschens, schwankenden Positionierungsgenauigkeiten z.B. durch schwankende Verfügbarkeit von Korrektursignalen (insb. SAPOS), sowie die Schließung von Lücken in Bereichen ohne GNSS-Empfang durch klassisches SLAM. Eine so erstellte Karte enthält keine Positionsdrift relativ zu einem Startpunkt der Messung und nach hinreichend vielen Fahrten eine weitestgehend gleichmäßige Genauigkeit der fusionierten Messpunkte. Verbleibende Grenzfälle sind jene Regionen, in denen eine Absolutpositionierung auch bei Mehrfachbefahrung nicht gelingt, bspw. in Tunnels, mit der Folge dass die Positionsgenauigkeit hier zur Tunnelmitte hin zunimmt. Prinzipiell besteht hier im Rahmen einer Nachbearbeitung die Möglichkeit durch Integration weiterer Daten anderer Messungen (z.B. Gebäudevermessung mit Totalstation). Der Vorteil dieser Methode wird dann deutlich, wenn die Kartierung durch Fahrzeuge im Regelverkehr erfolgt, die Karten laufend und automatisiert aktualisiert werden, und wenn die Karten durch entsprechende Datendienste allen Verkehrsteilnehmern zur Verfügung gestellt werden. Hierzu wurde in parallel laufenden Projekten, insbesondere *European Digital Dynamic Mapping* [29], eine entsprechende Client-Server-Methodik konzipiert [14, 30], mit dem Ergebnis, dass bei entsprechender Kartenverfügbarkeit eine höhere Absolutgenauigkeit erreicht werden kann als mit alleiniger Satellitennavigation (Abbildung 65).

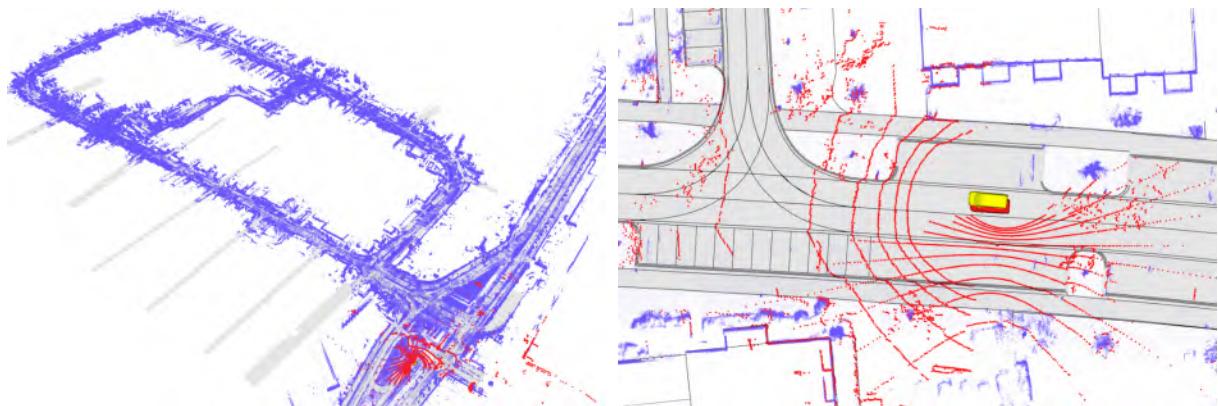


Abbildung 65: LiDAR-Punktwolkenkarte des Versuchsgelände (links), Ergebnisse der absoluten LiDAR-gestützten Positionierung (rot) im Vergleich zu GNSS/INS (gelb). Die Registrierung der Sensordaten erfolgt insbesondere an Gebäudekanten.

1.2.3.4. Segmentierung von LiDAR-Punktwolken

Grundlage für die Arbeiten sind Deep-Learning-Verfahren zur semantischen Segmentierung von LiDAR-Punktwolken [31]. Die publizierten vortrainierten Modelle wurden zumeist mit öffentlichen Datensätzen wie *SemanticKITTI* [32] erstellt und zeigen bei Anwendung auf die eigenen Sensoren, Fahrzeuge und Verkehrsumgebungen eine erwartbar verringerte Leistung. Verfahren

zur Domänenadaptation [33] dienen jetzt dazu, die Modelle auf die eigenen Bedingungen möglichst automatisiert anzupassen, ohne dass ein umfangreiches überwachtes Lernen mit manueller Annotation erforderlich ist.

Beim Anwenden der Deep-Learning-Modelle auf die eigenen Punktwolken-Datensätze führt der durch die unterschiedlichen verwendeten Sensoren bedingte Domänenprung zu einem erheblichen Qualitätsverlust (siehe Abbildung 66). Dieser Effekt ist scheinbar bei allen Formen von Punktwolken verarbeitenden Architekturen zu finden. Verifiziert haben wir dies auf

- PointNet-basierten Architekturen, die auf Basis der Nachbarschaftsbeziehungen arbeiten,
- Projektions-basierten Architekturen, die im Kern CNNs auf Tiefenkarten anwenden, sowie
- Voxel-basierten Architekturen, die zunächst die Punkte in ein Voxelgitter anlegen und anschließend 3D-CNNs auf die Voxelstruktur ausführen.

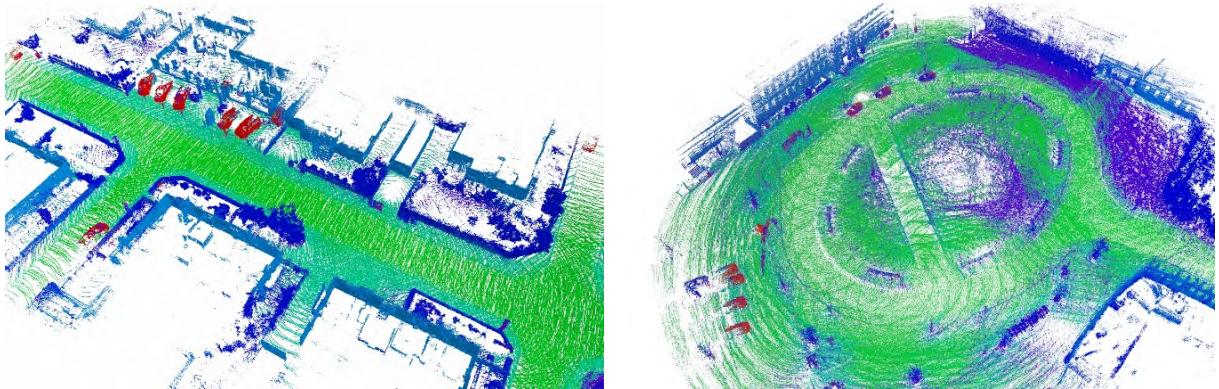


Abbildung 66: Vergleich der Qualität der LiDAR-Segmentierung nach Aggregation aufeinanderfolgender Punktwolken auf der Quelldomäne (links) und Zieldomäne (rechts).

Um dem entgegenzuwirken, haben wir ein Domänenadaptionsverfahren entwickelt, implementiert und getestet, mit dem wir diesen Domänenprung bewältigen konnten (siehe Abbildung 67). Wir können das Ergebnis auf unseren Sensordaten leider nicht quantitativ bewerten, da uns dazu die notwendige Ground-Truth auf unseren eigenen Sensordaten zum Vergleich fehlt. Weitere Domänenprünge sind durch die unterschiedlichen Geometrien in den Datensätzen (z.B. durch den Wechsel von urbaner zu ruraler Umgebung) sowie den unterschiedlichen Skalen und Messmethoden zur Reflektivität (Remission) mit Laser verursacht (siehe z.B. Spezifikation *Velodyne HDL64e* vs. *VLP32-c*). Die Remissionsmessung ist notwendig für eine zuverlässige Detektion von Spurmarkierungen. Für eine spurgenaue Lokalisierung müssen hier also noch Domänenadaptionsmethoden entwickelt werden, sodass der zur Navigation relevante Fahrstreifen im Umfeld wahrgenommen werden kann (siehe folgender Abschnitt).

1.2.3.5. Automatisiertes Lernen von Fahrstreifen

Wendet man ein KI-Modell auf Daten an, die beim Training des Modells nicht gesehen wurden, so kann es zu drastischem Abfall der Qualität führen, falls die ungesiehenen Daten aus einer anderen Domäne stammen (z.B. durch Sensorwechsel induziert). Im vergangenen Abschnitt haben wir

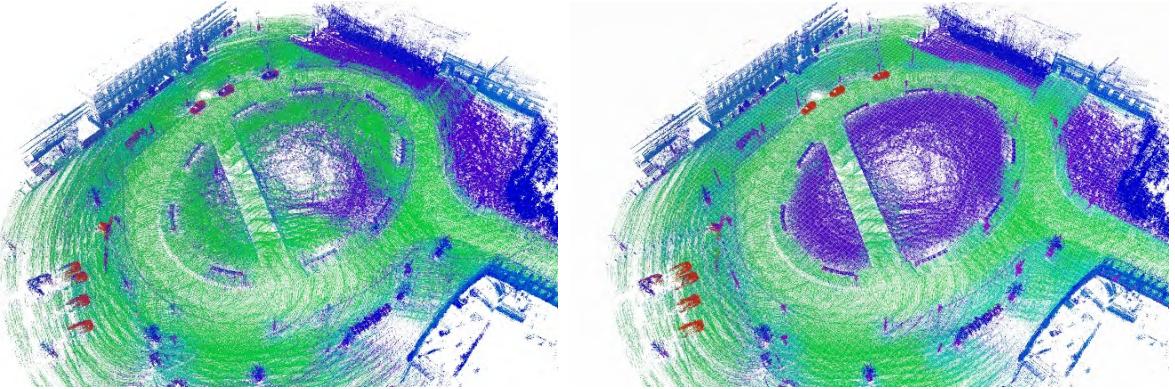


Abbildung 67: Vergleich der Segmentierung ohne (links) und mit (rechts) Domänenadaption.

bereits eine Methode untersucht, um diese Domänen sprünge vom Trainingsdatensatz hin zu den eigenen Sensordaten mittels Domänenadaption zu bewältigen. Hier kam uns zu Gute, dass unsere eigenen Sensordaten eine geringere Auflösung aufweisen, als die für die Erzeugung des Trainingsdatensatzes benutzten Sensordaten.

Im Fall des neu aufgebauten Fahrzeugs ist die Auflösung unserer Sensordaten jedoch um mehr als eine Größenordnung höher (ca. Faktor 12). Dadurch können wir keinen Datensatz mit dem verwendeten (oder einem vergleichbaren) Verfahren zur Domänenadaption bzw. dem Training eines KI-Modells heranziehen. Um eine Inferenz auf Punktwolken bzw. Punktwolken-Karten mit solch hochauflösten Daten dennoch durchführen zu können und gleichzeitig die Vorteile der Informationsdichte ausnutzen zu können, verfolgen wir eine neue Strategie zur automatisierten Generierung von Trainingsdatensätzen. Dazu projizieren wir OpenDrive-Karteninformationen auf die Punktwolken und leiten somit Label für die Punktwolken ab. Hier ist eine hochpräzise Lokalisierung notwendig, um die Label korrekt auf die Punkte zu projizieren.

Hierzu wurde in zwei Phasen das *PCLane-ROS*-Paket entwickelt, um mithilfe von Deep-Learning Computer-Vision Architekturen eine präzise Lokalisierung zu ermöglichen. In der ersten Phase wird ein Trainings-ROS-Paket mit zwei Datenextraktionsknoten und einem Trainingsknoten entwickelt. Die beiden Datenextraktionsknoten dienen dazu, Punktwolkendaten aus den LiDAR-Scans, die während verschiedener Messkampagnen gesammelt wurden, sowie Straßengeometriedaten aus OpenDrive-Karten zu extrahieren, siehe Abbildung 68. Die Punktwolken dienen während des Trainings und der Inferenz als Eingabe für die Deep-Learning Architektur.

Die Ground-Truth für das Training wird aus der OpenDrive-Karte erstellt. Basierend auf der initialen Schätzung der Fahrzeugposition durch globale Positionierung wird der lokale Straßenabschnitt bestimmt, auf dem sich das Fahrzeug aktuell befindet. Der OpenDrive-Kartenknoten bestimmt auf Basis der anfänglichen Positionsschätzung die Informationen über die vorausgehenden und nachfolgenden angrenzenden Straßenabschnitte. Die so ermittelten Straßenabschnitte enthalten auch Informationen über die Fahrstreifen in den angrenzenden Straßenabschnitten, was zur Bestimmung des aktuellen Fahrstreifens des Fahrzeugs führt (Abbildung 69). Da die Geometrie der Fahrstreifen eines Straßenabschnitts ebenfalls in die OpenDrive-Karten integriert ist, extrahiert der Knoten die Informationen über den Typ und die Parameter der Geometrie der Spur aus den vorausgehenden und nachfolgenden Straßenabschnitten. Eine OpenDrive-Karte

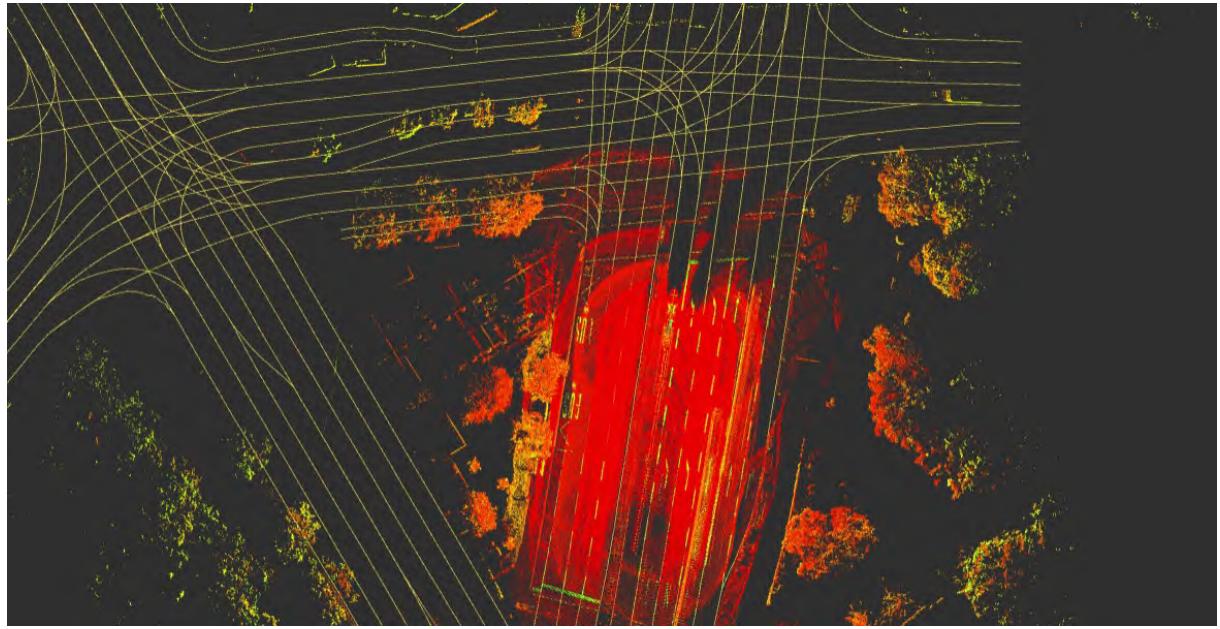


Abbildung 68: Visualisierte Punktwolkendaten und überlagerte OpenDrive-Karte. In den LiDAR-Punkten mit Remissionswerten sind Bodenmarkierungen gut erkennbar.

kategorisiert die Geometrie von Fahrstreifen typischerweise in gerade Abschnitte, die durch gerade Linien definiert sind, Abschnitte mit konstanter Krümmung, die durch Kreisbögen definiert sind, und Abschnitte mit variabler Krümmung, die als parametrische kubische Polynome oder Klothoiden definiert sind.



Abbildung 69: Standarddarstellung einer Kreuzung in der OpenDrive-Karte mit Vorgänger- und Nachfolgeknoten der einzelnen Elemente.

Der Trainingsknoten wird die Punktwolkendaten und die geometrischen Parameter der Fahrstreifen, die jeweils von den LiDAR- und OpenDrive-Kartenknoten extrahiert werden, nutzen, um die Deep-Learning-Architektur zu trainieren, um die Geometrien der vorausgehenden und nachfolgenden Fahrstreifen für eine maximale Entfernung von (hier beispielhaft) 50 m von der aktuellen Fahrzeugposition zu bestimmen. Zwei Arten von Architekturen sind für die Anwendung zur Fahrstreifenerkennung und Vorhersage der Spurengeometrie geeignet: Regression und Segmentierung. Zunächst wird das Training auf Architekturen durchgeführt, die eine Regression auf gerade und konstant gekrümmte Abschnitte durchführen, um die Leistung und die

Einschränkungen von Regressionsmodellen im Kontext der Fahrstreifenerkennung und Geometrievorhersage für verschiedene Straßenabschnitte während des Trainings und der Validierung mit den Messkampagnendaten zu bewerten und zu analysieren. Basierend auf den Erkenntnissen zur Leistung des Regressionsmodells wird eine Segmentierungsarchitektur in Betracht gezogen, um den aktuelle Fahrstreifen zu erkennen und die Punkte der Punktwolke, die dem aktuellen Fahrstreifen entsprechen, zu segmentieren. Diese segmentierten Punkte werden dann als Eingabe genutzt, um die Regression der vorausgehenden und nachfolgenden Fahrstreifengeometrien zu unterstützen.

In der zweiten Phase wird die Funktionalität der Deep-Learning-Modellarchitektur weiter ausgebaut, um Fahrstreifen zu erkennen und die Geometrien benachbarter Fahrstreifen zum aktuellen Fahrstreifen des Fahrzeugs in den vorausgehenden und nachfolgenden Straßenabschnitten der OpenDrive-Karte vorherzusagen. Das Training wird sich insbesondere auf die Erkennung verschiedener Fahrstreifen in komplexen Straßenabschnitten wie Kreuzungen, Abzweigungen sowie Zusammenführungs- und Abzweigespuren konzentrieren, die besondere Aufmerksamkeit hinsichtlich der Datengenerierung, der Trainingsstrategie und der Optimierung der Architektur erfordern (Abbildung 70). Ein Transfer-Learning-Ansatz wird angewendet, um das in der ersten Phase erworbene Wissen auf die optimierte Architektur zu übertragen, die für die Vorhersage komplexer Straßenabschnitte und Geometrien geeignet ist. Die Integration des Modells in die On-Vehicle-Inferenzpipeline zum Testen des Modells mit Echtzeitdaten und realen Fahrtests wird durchgeführt.

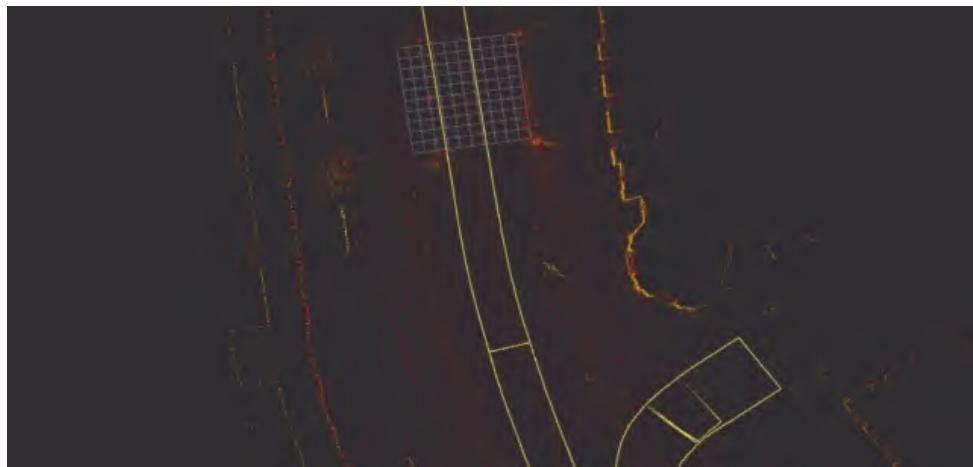


Abbildung 70: Extraktion von Fahrstreifen-Polygonen aus der OpenDrive-Karte zur Vereinfachung der Daten für nachfolgende Bearbeitungsschritte (Fahrzeug ist in der Mitte der Gitterstruktur).

Die geometrische Information des Fahrstreifenpolygons wird schließlich zum automatisierten Labeling der damit korrespondierenden LiDAR-Punktwolken verwendet (vgl. Abbildung 68). Auf der Grundlage dieser generierten entsprechenden Labels wird eine auf Deep Learning basierende Segmentierungsarchitektur für die Erkennung des aktuellen Fahrstreifens und die Segmentierung der Voxel in der Punktwolke, die dem aktuellen Fahrstreifen entsprechen, trainiert. Die segmentierten Voxel aus der Punktwolke können als Eingabe verwendet werden, um ein weiteres Deep-Learning-Modell zu trainieren, das auch für die Regression der vorhergehenden und

nachfolgenden Fahrstreifengeometrien verwendet wird. Der Trainingsknoten verwendet dann die Punktwolkendaten und die geometrischen Parameter der Fahrstreifen, die von den LiDAR- bzw. OpenDrive-Kartenknoten extrahiert wurden, um die Deep Learning-Architektur für die Ableitung der vorausgehenden und nachfolgenden Fahrstreifengeometrien zu trainieren.

Für das Trainieren des KI-Modells wird die *PointNet*-Architektur [34] als Backbone verwendet. Die Architektur besteht aus einer lokalen und einer globalen Strategie zur Merkmalsextraktion, wie in Abbildung 71 zu sehen ist. Das Klassifizierungsnetzwerk nimmt eine feste Anzahl von n Punkten als Eingabe, wendet Eingabe- und Merkmalstransformationen an und aggregiert dann Punktmerkmale durch Max-Pooling. Die Ausgabe sind Klassifizierungsergebnisse für k Klassen. Das Segmentierungsnetz ist eine Erweiterung des Klassifizierungsnetzes. Es verknüpft globale und lokale Merkmale und gibt die Punktwerte pro Klasse aus.

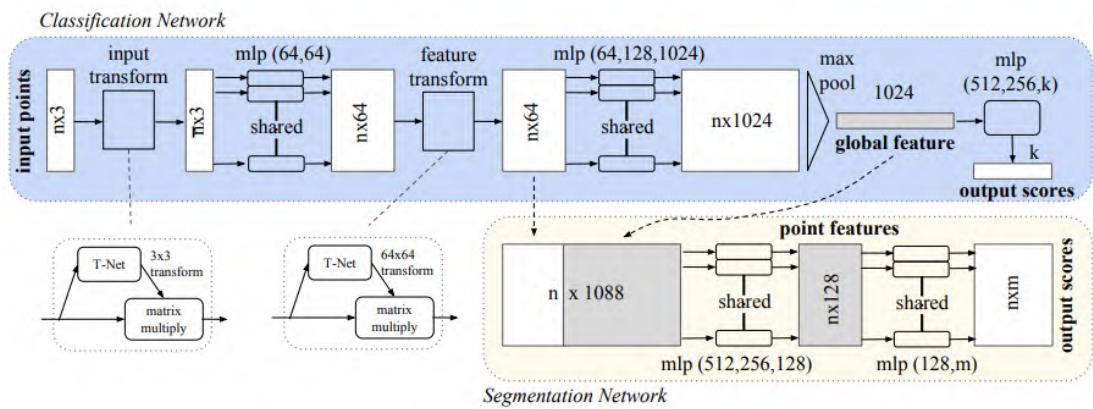


Abbildung 71: PointNet-Architektur, aus [34].

Nach der Erhebung der Messdaten im Rahmen von Fahrversuchen wurden die LiDAR-Punktwolken mithilfe der beschriebenen Strategie über die OpenDrive-Karte automatisiert annotiert. Basierend auf der Segmentierung der LiDAR-Voxel durch das trainierte Deep-Learning-Modell, die dem aktuellen Fahrstreifen des Ego-Fahrzeugs entspricht, wurde ein Fahrstreifenpolygon extrahiert, das den befahrbaren Bereich im aktuellen Fahrstreifen vor und hinter dem Ego-Fahrzeug anzeigt und dadurch der Fahrstreifen und die entsprechenden Voxel aus jeder Punktwolke klar abgrenzt, siehe Abbildung 72. Die Segmentierung des fahrzeugzugehörigen Fahrstreifens und dessen geometrischer Hülle wurde in das PCLane-Softwaremodul integriert. Nach Training eines Segmentierungsmodells mit Kartendaten ist dieses, sofern robust lauffähig, unabhängig von Kartendaten bei der Anwendung für die Fahrstreifenbezogene Positionierung. Das Verfahren wurde unter [35] publiziert.

1.2.3.6. Semi-Automatisiertes Kalibrierverfahren zur Referenzdatenoptimierung

Zur Gewinnung von Referenzdaten wurden im Projektverlauf folgende Arbeiten ausgeführt:

- Implementierung eines Verfahrens zur automatisierten Kalibrierung von Infrastrukturkameras, unter Verwendung von eingemessenen Landmarken am Boden,

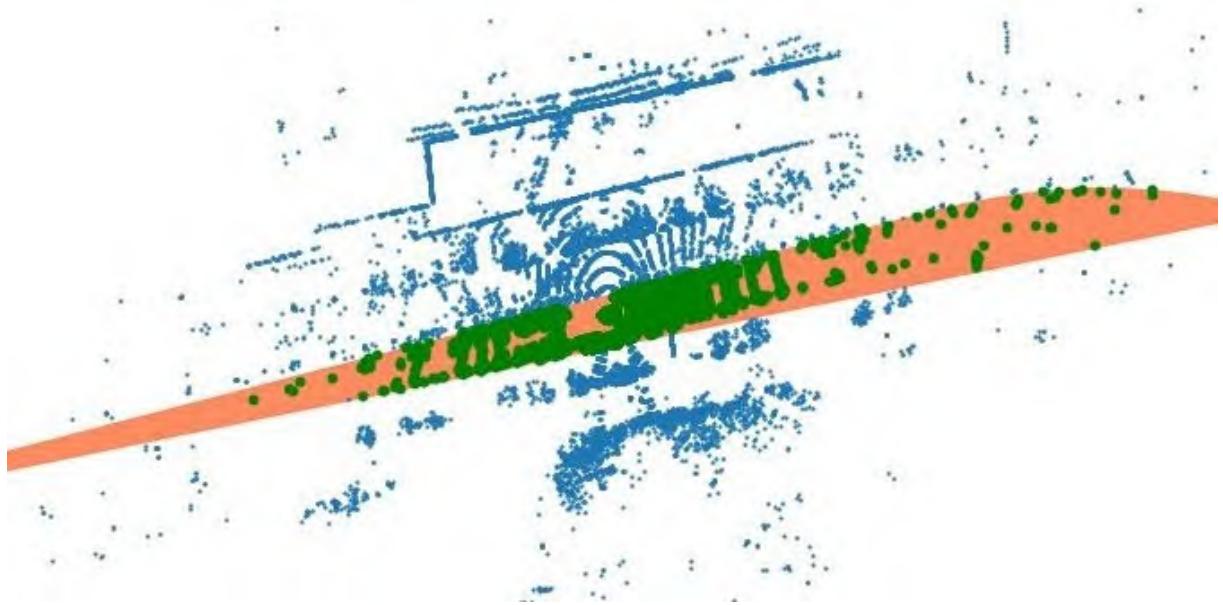


Abbildung 72: Voxel der Punktfolge, die der aktuellen Fahrspur des Ego-Fahrzeugs (grün) entsprechen, überlagert mit dem Fahrspurausschnitt der Opendrive-Karte (orange) und Voxeln aus dem Rest der Punktfolge (blau).

- Optimierung der Erfassung genauer Bildzeitstempel in den Referenzmesssystemen zur Sicherstellung der Synchronität zwischen Fahrzeug- und Referenzmessdaten,
- Weiterentwicklung von Verfahren zur Objekterkennung bzw. Objekttracking im Hinblick auf eine genauere Objektpositionsbestimmung aus Referenzkameraperspektiven,
- Aufbau einer tragbaren Road Site Unit als Ergänzung bestehender Infrastruktur zur mobilen und flexiblen Erfassung von Referenzdaten,
- Aufnahme von kalibrierten und synchronisierten Referenzdaten bei den Fahrversuchen mit stationärer Infrastruktur (Fahrzeughänger, siehe Abbildung 3 auf Seite 15), Drohne und mobiler Road Site Unit, siehe Abbildung 73.

Für die Gewinnung von zeitlich und räumlich validen Referenzdaten ist eine Kalibrierung der Messsysteme erforderlich. Grundsätzlich lässt sich eine zeitlich hinreichende Genauigkeit durch Verwendung von GNSS und PPS-basiertem Trigger und entsprechender Zeitstempelerstellung erreichen. Räumlich bedeutet dies im Wesentlichen die Registrierung der Sensordaten mit georeferenzierten Landmarken. Für LiDAR-Daten kann das gleiche Verfahren wie zur Fahrzeugnavigation eingesetzt werden; hier ist sicherzustellen, dass ausreichend genau georeferenzierte und wiedererkennbare Landmarken aus der Punktfolgenkarte zur Verfügung stehen. Zur Bestimmung der Kameraorientierung gilt dies analog für im Bild erkennbare Muster. Als Referenzbild kommen z.B. georeferenzierte Luftbilder infrage, sowie Bilder mit entsprechend eingemessenen Landmarken. Die Bestimmung der Parameter kann letztendlich mit Verfahren wie dem in [36] beschriebenen P3P-Solver erfolgen.

Unabhängig vom verwendeten Sensor stellt die Sicherstellung einer validen Referenzmessung im praktischen Einsatz eine Herausforderung dar, da sich auch stationär befestigte Messsysteme

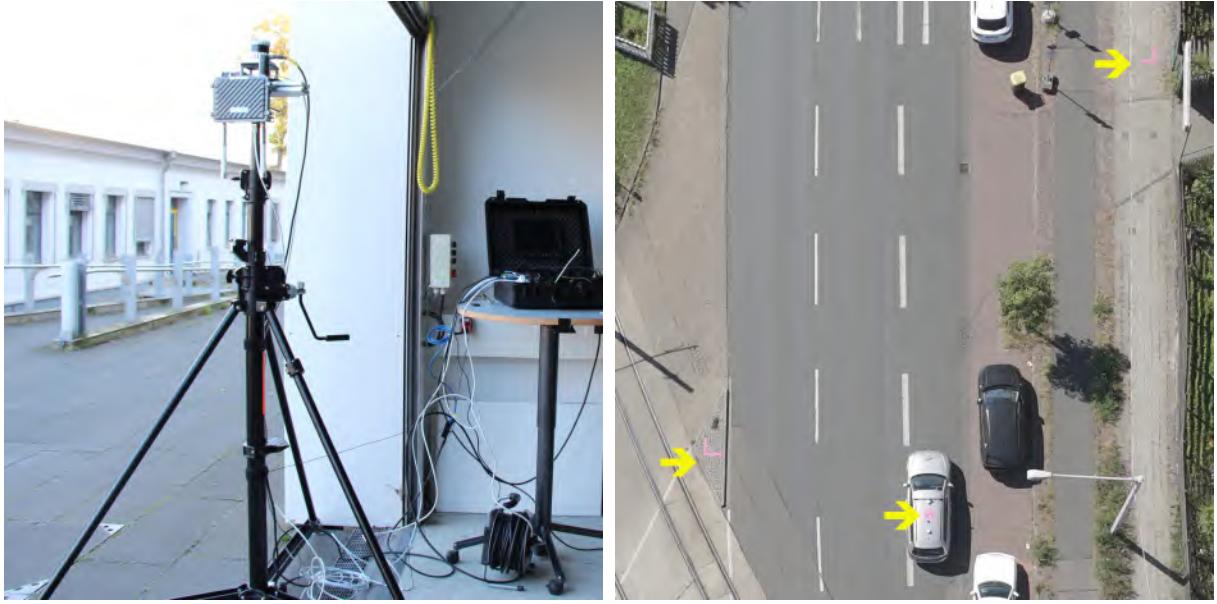


Abbildung 73: Im Projekt aufgebaute mobile Road Site Unit zur Aufnahme von Referenzdaten aus bis zu 3,50 m Höhe (links), zu sehen ist die Montage eines LiDAR sowie einer Cohda Wireless RSU zur Kommunikation. Drohnenaufnahmen mit Geo-Referenzmarken am Boden und Markierung am Fahrzeug (rechts).

dynamisch verhalten. Bei der betrachteten Anwendung sind insbesondere temperaturbedingte Verformungen und witterungsbedingte Schwankungen eines Sensormasts bzw. die Bewegungen einer Kameradrohne bedeutsam, und es zeigt sich, dass die extrinsische Sensororientierung idealerweise für jedes Referenzbild zu bestimmen ist. Ausgehend von synchronisierten Fahrzeug- und Referenzdatenaufnahmen und Unterstützung durch eingemessene Passpunkte (siehe Abbildung 73) sollten alle weiteren Schritte automatisiert ablaufen. Im Folgenden wird das für Kameras entwickelte Verfahren beschrieben, da wir vorrangig eine Kamera aus Drohnen- oder Sensormastperspektive zur Referenzdatengewinnung verwendet haben.

Aufgrund der starken Änderung der visuellen Repräsentation zwischen Luft- und Kamerabild ist die automatische Auswahl der Punktkorrespondenzen eine besondere Herausforderung. Es wurden unterschiedliche Ansätze zur Detektion und Beschreibung der visuellen Merkmale mit einem Feature-Vektor betrachtet, die unter starker affiner Deformation möglichst stabile Repräsentationen liefern. Dabei fiel die Wahl auf einen Ansatz, der als *Vision Transformer* (ViT) bezeichnet wird und das Potential hat, eine besonders hohe Abstraktionsfähigkeit für Merkmale im Bild zu erreichen.

In den Experimenten kam ein vortrainiertes *ViT-B14*-Modell, das mit dem *DinoV2* Framework [37] selbstüberwacht trainiert wurde, zum Einsatz, um dichte visuelle Merkmale zu extrahieren. Die Aufgabe der automatischen Bildkalibrierung hängt in hohem Maße von der Qualität der Merkmale ab, die aus den betreffenden Bildern extrahiert werden. *DinoV2* ist in der Lage, robuste visuelle Merkmale zu finden und einen Merkmalsvektor für diese auszugeben, der es ermöglicht, die Merkmale korrekt zu assoziieren. Abbildung 74 zeigt ein entsprechendes Beispiel. Anschließend erfolgt die Bestimmung der Kameraorientierung durch das oben referenzierte P3P-Lösungsverfahren mit jedem Bild automatisch.

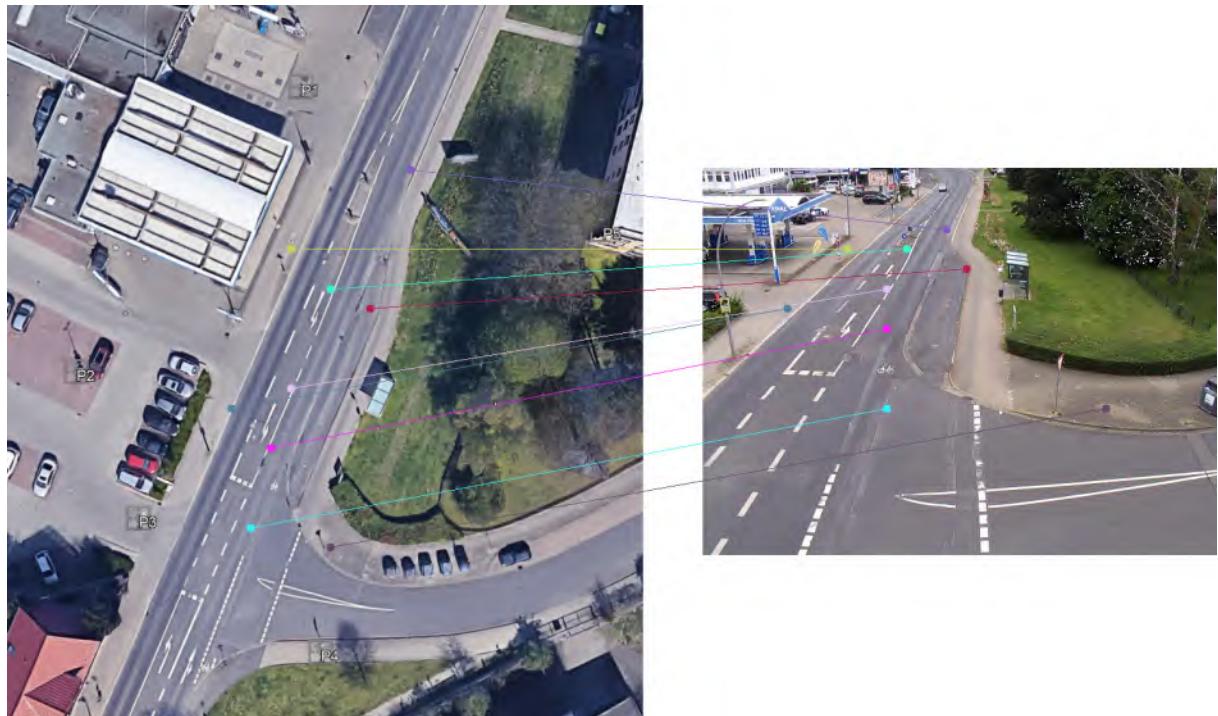


Abbildung 74: Automatische Auswahl von Punktkorrespondenzen zur Kalibrierung mit einem georeferenzierten Luftbild.

Abseits von Ungenauigkeiten im Bildraum (z.B. Unschärfe und Wiedererkennbarkeit von Mustern) ist es offensichtlich, dass die Qualität der Referenzdaten vor allem von der Georeferenzierung der Landmarken im Referenzbild abhängt. Um möglichst genaue Daten zu erhalten, wurden in den Versuchen ca. 15 Marker im Kamerasichtfeld auf den Boden geklebt und mittels Langzeit-GNSS-Messung und SAPOS-Korrektur eingemessen. Das Resultat ist eine Absolutgenauigkeit von ca. 2–3 cm für die GNSS-Messung. Bei einer Pixelauflösung von etwa 5 cm (Drohnenaufnahme aus der gewählten Flughöhe) und einer angenommenen subpixelgenauen Bestimmung der Korrespondenzen mit etwa 0,5 Pixel Genauigkeit resultiert daraus letztendlich eine Genauigkeit von etwa 4 cm. Die Bestimmung einer Fahrzeugreferenzposition wird dann in dieser Größenordnung erreicht, wenn eine auf dem Fahrzeug befestigte Markierung ebenfalls mit 0,5 Pixeln Genauigkeit bestimmbar ist. Bei den Referenzaufnahmen vom Kameramast ist die Pixelauflösung nicht als konstant anzunehmen, da es sich hier um eine Schrägaufnahme handelt und bei weiter entfernten Objekten eine geringere Pixelauflösung vorliegt. Hier kann, abhängig von der tatsächlichen Pixelauflösung und abhängig von der konkreten Einstellung des Sensors von einer ungefähren Genauigkeit von bis zu 2 cm im Vordergrund und etwa 10–15 cm im mittleren Bildbereich ausgegangen werden.

1.2.3.7. Versuchsdurchführung und Evaluation

Neben entwicklungsbegleitenden Experimenten mit den Einzelsystemen Fahrzeug, Drohne, mobile Messtation usw. sind die Versuchskampagnen zur langfristigen Datenaufnahme und zur Betrachtung des Gesamtsystems unter Abschnitt 1.1 bei den Arbeitspaketen aufgelistet. Abbildung zeigt eine Aufnahme des Versuchs im August 2025.

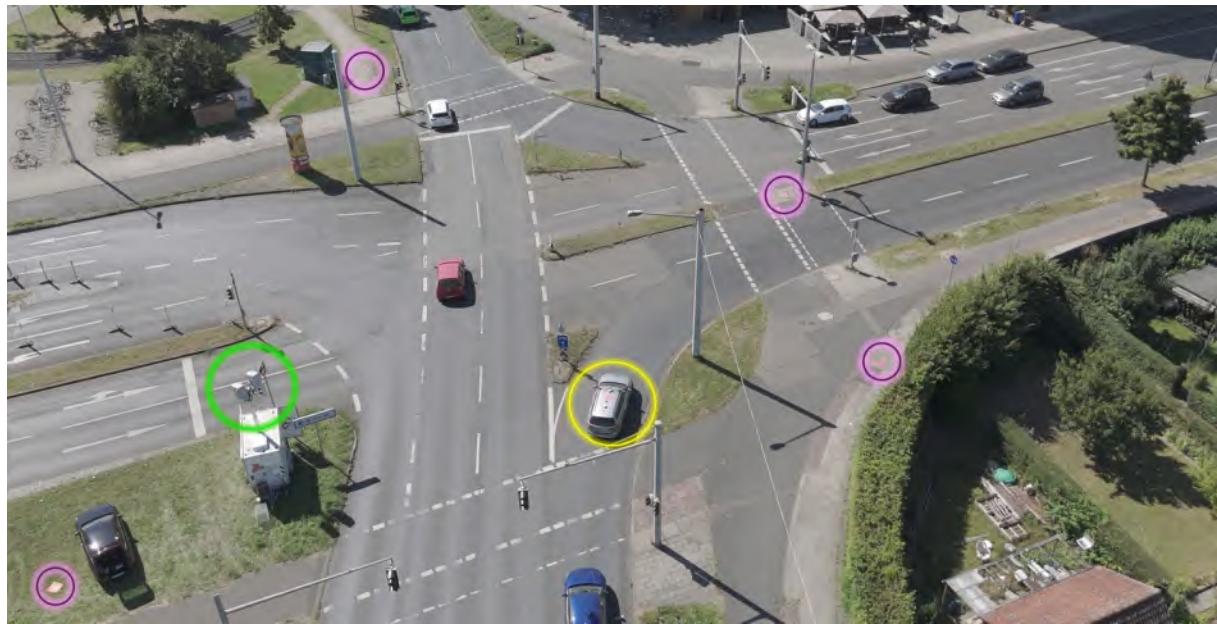


Abbildung 75: Drohnenaufnahme eines Fahrversuchs in Braunschweig. Gekennzeichnet sind das Versuchsfahrzeug (gelb), die stationäre Referenzkamera (grün), sowie die eingemessenen Referenzmarker am Boden (lila).

Der Ablauf ist in allen Versuchskampagnen vergleichbar:

1. Vortests von Fahrzeug und Referenzsystem zur Sicherstellung der Lauffähigkeit der Einzelkomponenten,
2. Für automatisierte Fahrten: Validierung der Funktionen im automatisierten Betrieb im nichtöffentlichen Gebiet,
3. Einholen der erforderlichen Genehmigungen zum Aufstellen der stationären Systeme und zum Fliegen der Drohne,
4. Platzierung und Einmessung der Referenzmarker am Boden,
5. Aufstellen und Kalibrieren des Referenzsystems,
6. Durchführen der Messfahrten bei gleichzeitigen Aufnahmen mit den Referenzsystemen inkl. Drohnenflügen.
7. Nachbereitung zur Sicherung der Messdaten und zur Auswertung.

Neben Versuchen zur maßgeblichen Gewinnung von Daten im manuellen Fahrbetrieb wurden auch Versuche im automatisierten Betrieb durchgeführt. Hierbei hat das unter 1.2.3.3 beschriebene Verfahren (Kombination LiDAR, GNSS, INS, hier allerdings ohne die Erweiterungen zur semantischen Segmentierung und zur KI-basierten Fahrstreifenerkennung) einen Reifegrad erreicht, bei dem eine stabile absolute Position unter Echtzeitbedingungen und im Fahrbetrieb reproduzierbar ermittelt werden kann. Die Positionsausgabe ersetzt über eine kompatible Schnittstelle die bisherige Verbindung von NovAtel-GNSS/INS und Automationssoftware [38].

Insgesamt konnten die automatisierten Fahrten erfolgreich durchgeführt werden. Wir haben die LiDAR-gestützte Navigation in das Fahrzeug-Gesamtsystem so integriert, dass sie auch in anderen Projektversuchen eingesetzt wird. Zur Auswertung der Messdaten wird hier auf die oberen Abschnitte sowie auf die eigenen Publikationen verwiesen.

1.2.4. Universität Göttingen

1.2.4.1. Punktwolkenregistrierung mittels Gauß-Wassersteindistanzen für LiDAR-Odometrie

Moderne LiDAR-Sensoren liefern äußerst dichte Punktwolken mit hohem Detailgrad, welche jedoch stark reduziert werden müssen, um eine Odometrie in Echtzeit gewährleisten zu können. Konventionelle LiDAR-Odometrie-Methoden können hier also nur bedingt von der hohen Auflösung moderner Sensorik profitieren. In diesem Zuge beschäftigt sich die UGOE mit Registrierungsalgorithmen basierend auf LiDAR, die nicht nur Punkte, sondern aus Punkten akkumulierte Merkmale verwenden. Konkret wurde ein Registrierungsverfahren entwickelt, bei dem die Punktwolken zu Mengen von multivariaten Gaußverteilungen konvertiert werden, die jeweils die lokale Geometrie an einer Stelle zusammenfassen. Mittels eines iterativen Verfahrens basierend auf ICP wird dann eine Transformation bestimmt, die den Versatz und die Rotation zwischen Punktwolken schätzt. Sequentiell auf LiDAR-Scans angewandt, ergibt sich so ein Verfahren, das eine interne Karte aus Ellipsen konstruiert und kontinuierlich eine Posenschätzung mittels Registrierung von Scans gegen diese Karte produzieren kann. Hierbei ist eine Ähnlichkeit mit verschiedenen existierenden Ansätzen gegeben. Das Approximieren lokaler Geometrie durch Gauß-Verteilungen und somit Ellipsen wurde von Biber und Straßer [39] vorgeschlagen. *LiTAMIN* [40] und die Weiterentwicklung *LiTAMIN2* [41] sind neuere Methoden, die einen ähnlichen Ansatz verfolgen. Ein elementarer Unterschied zum an der UGOE verfolgten Ansatz ist dabei das eingesetzte Distanzmaß für die Ellipsen bzw. Gaußverteilungen.

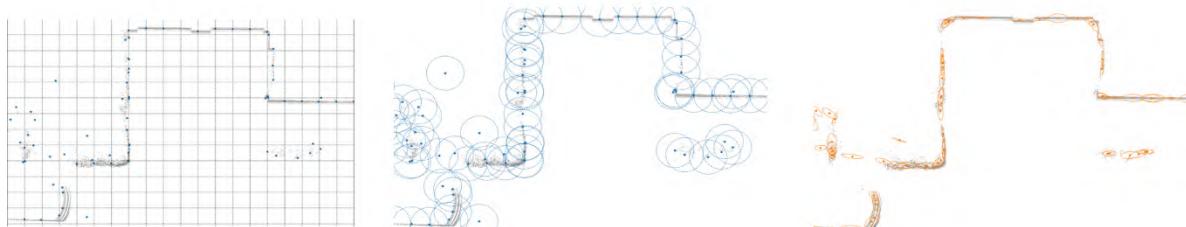


Abbildung 76: Schlüsselpunkte, Einzugsradien und entstehende Ellipsen in der vorgeschlagenen Verarbeitungspipeline

Die Verarbeitungspipeline des erarbeiteten Algorithmus *GWD-ICP* [42] ist ähnlich der Pipeline des punktbasierten *KISS-ICP*. Zunächst werden Schlüsselpunkte innerhalb einer gitterbasierten Voxelisierung identifiziert (Abb. 76, links). Zu jedem Schlüsselpunkt werden alle Punkte innerhalb eines definierten Einzugsradius (Abb. 76, mittig) zusammengefasst. Aus diesen Punkten wird die lokale Geometrie als multivariate Gaußverteilung geschätzt. Aufgrund der dreidimensionalen Struktur der LiDAR-Scans ergeben sich somit 3D-Gaußverteilungen. In einer „geschnittenen“ Aufsicht ergeben sich Ellipsen (Abb. 76, rechts).



Abbildung 77: Schematisches Registrieren zwischen Karte (grau) und neuem Scan (orange).

Gaußverteilungen aus dem neuen Scan werden bestehenden Informationen in der internen Karte zugeordnet (Abb. 77, links). Gegeben diese Zuordnung, wird eine Transformation gesucht, die die Abstände der zueinander assoziierten Verteilungen minimiert. Intuitiv führt dies zu einer Anpassung der beiden Mengen (Abb. 77, mittig). Basierend auf dieser Transformation können neue Verteilungen in die Karte eingefügt werden (Abb. 77, rechts), was das „Sichtfeld“ der Karte erweitert.

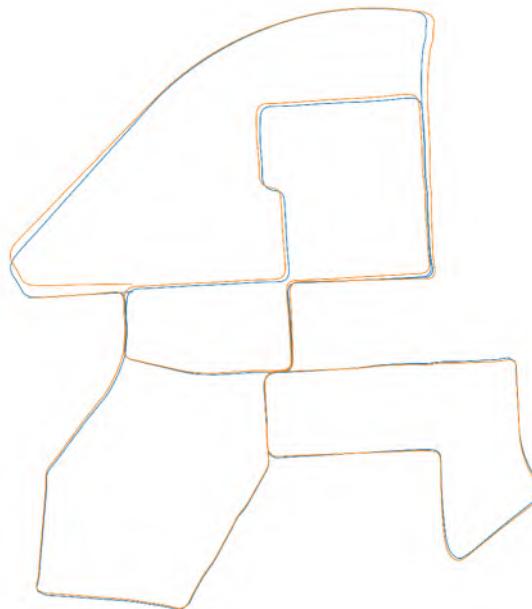


Abbildung 78: Beispielhafte Trajektorienschätzung des erarbeiteten Algorithmus (orange), gegen die tatsächliche Fahrtstrecke (blau).

Beispielhafte Ergebnisse des Algorithmus sind in Abbildung 78 gezeigt. Die zugehörigen Daten sind Teil des öffentlichen Datensatzes *KITTI* [43], mit dem Teile der Evaluation durchgeführt wurden. Zu sehen ist, dass der Algorithmus die Fahrtstrecke gut schätzen kann, dabei allerdings gegen Ende der Fahrt eine Drift beobachtet werden kann. Dieses Verhalten ist ein inhärentes Problem von LiDAR-Odometrie und kann nicht ohne Zunahme von zusätzlichen Daten gelöst werden. Das Verhalten von der von uns entwickelten Methode ist diesbezüglich also vergleichbar zu anderen Methoden wie KISS-ICP. Ein Problem von GWD-ICP ist bisher eine unzureichende Robustheit gegenüber dynamischen Objekten, z.B. entgegenkommenden Autos oder Stausituationen. In diesen Situationen kommt es zu einer erheblichen Verschlechterung gegenüber KISS-ICP. Der entwickelte Ansatz wurde auf der Fachkonferenz „2023 IEEE Symposium Sensor Data Fusion and International Conference on Multisensor Fusion and Integration (SDF-MFI)“

vorgestellt und veröffentlicht [42]. Die Ergebnisse der bisherigen Forschung sprechen weder vollumfänglich für den Einsatz von merkmalsbasierten Methodiken (wie GWD-ICP), noch für rein punktbasierte Ansätze. Weitere Arbeiten diesbezüglich werden angestrebt.

1.2.4.2. Integration von Straßennetzkarten

Außerdem wurde an der UGOE eine Methode zur Fusion von Straßennetzkarten mit Odometriedaten entwickelt. Grundsätzlich kann hierbei auf eine beliebige Odometrieloösung, also beispielsweise LiDAR- oder IMU-basierte Systeme, zurückgegriffen werden. Bei dieser Methode kommt ein Partikel-Filter zum Einsatz. Hier repräsentiert jeder Partikel eine Hypothese über die Fahrzeugpose, bestehend aus Position und Orientierung. Die Gewichtung der Einzelhypothesen erfolgt über den Abgleich der jeweiligen Posen mit dem bekannten Straßennetz der Karte. Da hierbei eine exponentiell fallende Gewichtungsfunktion verwendet wird, werden Posen, die nicht mit der Karte konsistent sind, deutlich herabgewichtet. Dennoch werden solche Posen nicht mittels „harter“ Entscheidungen entfernt, sondern bleiben als Teil des probabilistischen Gesamtbilds der Positionierung erhalten. Dieser Ansatz bietet den Vorteil, dass ungenaue Karten nicht zur Elimination von eigentlich korrekten Hypothesen führen. Dies ist im Kontext des Projekts höchst relevant: Corner-cases, wie Baustellen, können oft zu geänderter Straßenführung führen und dürfen nicht dazu führen, dass korrekte Positionierungsergebnisse ausgeschlossen werden. Des Weiteren steigt auch die Robustheit gegenüber systematischen Fehlern in der Karte, wie nicht verzeichneten Straßenabschnitten. Um zu gewährleisten, dass die evaluierten Hypothesen mit hoher Wahrscheinlichkeit korrekt sind, wird das Sampling der zugrundeliegenden Verteilung durch die Odometrie als Input gestützt. Dadurch müssen weniger Hypothesen evaluiert werden, was die Echtzeitfähigkeit des Algorithmus verbessert.

Ähnliche existierende Methoden verwenden bspw. explizite Lokalisierungsschritte als Teil eines Monte Carlo Frameworks [44], oder diskrete Ankerpunkte, die evaluiert werden [45]. Roher Laserdaten können durch entsprechende Vorverarbeitungsschritte in Straßen- und nicht-Straßenpunkte geteilt werden, was einen Abgleich mit dem Straßennetz ermöglicht [46]. Im Gegensatz zu diesen Arbeiten ist die an der UGOE in Entwicklung befindliche Methode deutlich vereinfacht, was eine Effizienzsteigerung ermöglicht, und gleichzeitig unabhängig von Annahmen über die Sensorik des eingesetzten Systems. Abbildung 79 zeigt eine beispielhafte Trajektorie des KITTI-Datensatzes, auf der ein deutlicher Drift der reinen LiDAR-Odometrie (orange) zu sehen ist. Durch die Fusion mit der Straßennetzkarte kann dieser Drift eliminiert werden. In Abb. 80 ist die absolute Abweichung von der wahren Position, gemittelt über alle Trajektorien des KITTI-Datensatzes, zu sehen. In dieser quantitativen Analyse ist das driftende Verhalten der state-of-the-art LiDAR-Odometrie (orange) deutlich zu erkennen. Durch Integration von Kartendaten, gezeigt in Grün, kann der Drift eliminiert werden. Ein gewisser Fehler bleibt erhalten, allerdings steigt die Ungenauigkeit nicht mehr mit der Zeit. Gemittelt über den gesamten Datensatz kann der Fehler insgesamt um etwa 67% reduziert werden. Auch erste Vergleiche mit den oben genannten verwandten Arbeiten zeigen, dass die Methodik kompetitive Ergebnisse erzielen kann. Auch im Einsatz auf Messdaten der Konsortialpartner wurden Verbesserungen erzielt.



Abbildung 79: Driftende LiDAR-Odometrie (orange) und genaue Schätzung durch Integration der Kartendaten (grün).

1.2.4.3. Integration von Gebäudekarten

Des Weiteren wurde die Integration von Gebäudekarten mit der Odometrie zur Positionierung untersucht, was einen orthogonalen Ansatz zur zuvor diskutierten Integration von Straßennetzkarten darstellt. Die Gebäude, dargestellt durch Polygonzüge, können durch einfaches Sampling in eine Punktwolke überführt werden. Diese kann dann in einem subsequenten Angleichungsschritt mittels Iterative Closest Points (ICP) mit den Messungen des LiDAR-Scanners registriert werden. Zu diesem Zweck wird für jede LiDAR-Punktwolke eine initiale Schätzung zur Positionierung in der Karte benötigt. Für die erste Messung nach Ausfall der GNSS-Positionierung ist diese durch die zuvor vorliegende GNSS-Lokalisierung gegeben. Für ein fahrendes System ist allerdings bereits nach kurzer Zeit die letzte vorliegende Positionsschätzung aus GNSS nicht genau genug, um eine gute Registrierung mit den Karteninformationen zu gewährleisten. Daher wird im entwickelten Algorithmus ein Gesamtsystem aus lokaler Positionierung, z.B. LiDAR-Odometrie-Methoden wie KISS-ICP [47] und globaler Positionierung durch den Abgleich mit den aus Karten generierten Punktwolken eingesetzt. Im Kern des Systems liegt die Fusion der beiden Ergebnisse, bei denen die Positionsschätzungen aus lokaler und globaler Positionierung unter Berücksichtigung ihres individuellen Fehlerverhaltens berücksichtigt werden. Während die lokale Positionierung einen langsam ansteigenden Fehler aufweist (*dead reckoning*), ist die globale Positionsschätzung in der Regel stark verrauscht. Eine Fusion mittels Complementary Filter [48], welches oftmals für die Fusion von Gyroskop und Magnetometer benutzt wird, kann hier verwendet werden, da sich die Fehlerverhalten stark ähneln. Mit der eingesetzten Fusion ist das entwickelte System das erste unter vergleichbaren Algorithmen [49, 50, 51], für das Ergebnisse auf allen öffentlichen Trajektorien des KITTI-Datensatzes erzielt werden können. Im Mittel konnte

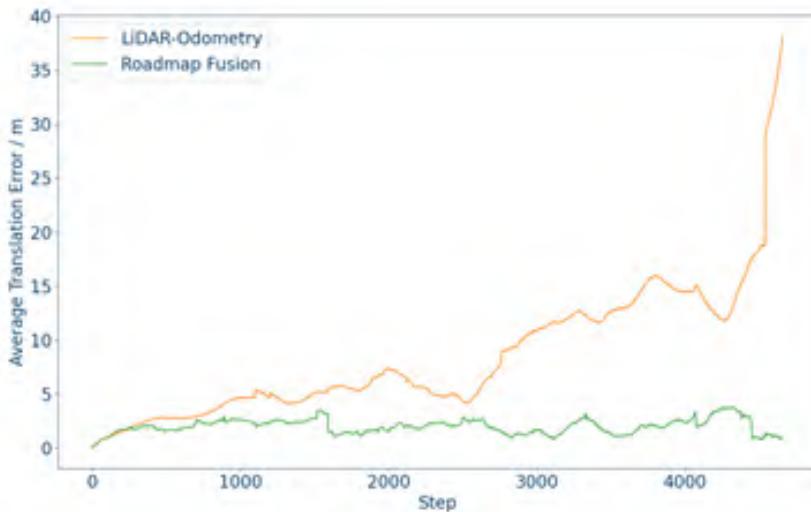


Abbildung 80: Fehler über Zeit von konventioneller LiDAR-Odometrie (orange) im Vergleich mit der von uns entwickelten Stützung mit Straßenwegenetze (grün).

die Genauigkeit der Positionsschätzung auf dem Datensatz um über 40% verbessert werden. Auch auf Daten der Konsortialpartner konnten ähnliche Ergebnisse beobachtet werden. Abb. 81 zeigt die Genauigkeit der Ergebnisse und der registrierten Punktwolken (grün), visualisiert im Direktvergleich mit den Gebäudekarten (schwarz) und dem reinen SLAM-Verfahren (orange).

1.2.4.4. Lidar-Odometrie Datensatz: Odyssey

Ein weiteres Anliegen ist die Aufnahme und die Publikation eines Datensatzes speziell für das Anwendungsgebiet LiDAR-Inertial-Odometrie. Die Datenaufnahme wurde von iMAR mit dem von ihnen entwickelten Messfahrzeug durchgeführt. Hierzu wurden mehrere urbane und ländliche Regionen in und um Saarbrücken mehrmals abgefahren. Existierende Datensätze setzen bei der Bestimmung der Ground Truth meistens auf MEMS oder FOG-basierten INS. Diese sind zwar preisgünstiger, bieten aber besonders in Situationen ohne GNSS-Signale nur suboptimale Schätzungen. Die Folge ist eine Unterrepräsentation von Situationen in z. B. Parkhäusern und Tunnels. Um genau diese Situationen genauer zu untersuchen, wurde ein hochgenaues INS (iPRENA-M-II) von iMAR benutzt. Im Gegensatz zu den MEMS oder FOG-basierten INS, bietet das RLG-basierte System eine signifikant höhere Genauigkeit und kann somit länger ohne stützende GNSS-Signale betrieben werden. Unsere Arbeit ist dabei der erste LiDAR-Inertial Datensatz mit einem RLG-basierten INS. Insgesamt beinhaltet der Datensatz ≈ 800 GB Daten in 12 einzigartigen Umgebungen. Hierbei wurde ein Datensatz mit hoher Diversität angestrebt, der nicht nur urbane, sondern auch ländliche Szenarien abdeckt. Diese Diversität gewährleistet, dass möglichst jede Situation des täglichen Verkehrs abgebildet wird. Ein zusätzlicher Fokus des Datensatzes liegt auf echten Umgebungen ohne GNSS-Signale wie z.B. Parkhäuser und Tunnel. Diese werden aufgrund der unzureichenden Genauigkeit von MEMS- und FOG-basierten INS in der Literatur oftmals vernachlässigt. Jede Fahrt wurde dabei drei Mal wiederholt, was insgesamt



Abbildung 81: Visualisierung der geschätzten Trajektorie (orange) und der lokalen Karte (grün) auf dem KITTI [43] Datensatz. Der Drift der Lidar-Odometrie (orange) konnte mithilfe der Kartendaten von OpenStreetMap [52] (grau) verhindert werden.

36 verschiedene Sequenzen ergibt. Somit unterstützt der Datensatz nicht nur LiDAR-Odometrie, sondern auch Place-Recognition-Methoden oder Methoden, die auf verwandten Daten trainiert werden müssen. Die Universität Göttingen übernahm bei der Erstellung dieses Datensatzes die Datensichtung, Datenaufbereitung und die wissenschaftliche Verwertung. Eine Publikation wird zur Zeit angestrebt, konnte jedoch nicht vor Ablauf des Projektes fertiggestellt werden.

1.2.4.5. Graphenbasierte LiDAR-Odometrie

Konventionelle LiDAR-Odometrie-Methoden schätzen die Position zu einem Zeitschritt, basierend auf der Positionsschätzung der vorherigen Zeitschritte, erlauben aber keine Korrektur der vorherigen Positionsschätzungen. Dieses Problem kann mithilfe von Pose-Graph-Optimization gelöst werden, die das retrospektive Modifizieren von vergangenen Posen erlaubt. Eine falsche Positionsschätzung, die vorher eventuell zu einer (zukünftigen) Divergenz der Methode geführt hätte, kann somit verhindert werden. Auch die Integrierung von zusätzlichen Sensordaten, wie beispielsweise GNSS- oder IMU-Messungen, wird nativ von Pose-Graph-Optimization unterstützt. Grundsätzlich unterscheidet sich dieser Ansatz maßgeblich von den zuvor in diesem Projekt entwickelten Ansätzen. Während bei OSM-ICP und GWD-ICP auf eine ICP-Registrierung gegen eine lokale Karte in Form von akkumulierten LiDAR-Punktwolken gesetzt wurde, basiert diese Methode auf der separaten ICP-Registrierung gegen individuelle, vorherige Lidar-Punktwolken. Der neueste LiDAR-Scan wird gegen eine Menge von vorherigen LiDAR-Scans registriert. Jede Registrierung entspricht einer Kante im Pose-Graphen und jeder LiDAR-Scan entspricht einem Knoten. Bei der Pose-Graph-Optimierung wird nun die Konfiguration von Knoten gefunden, die die Kanten am besten berücksichtigt. Die Optimierung ist jedoch ein iterativer Prozess, der

eine nicht zu vernachlässigende Menge an Zeit benötigt. Diese verbietet eine naive Implementierung, bei der eine große Menge an Knoten und Kanten im Graphen behalten werden. Die einfachste Möglichkeit ist, Knoten und Kanten aus dem Graphen zu entfernen. Dies ist jedoch nicht optimal, da mit dem Entfernen der Kanten auch wertvoll berechnete Informationen nicht mehr berücksichtigt werden können. Eine geschicktere Lösung ist die Kombination von mehreren Kanten in eine einzige Kante. Auch wenn eine solche Kombination nicht äquivalent mit dem originalen Graphen ist, ermöglicht sie die Anwendung unserer Methode in nahezu Echtzeit. Verwandte Ideen wurden bereits in [53, 54] vorgestellt. Diese Methoden fokussieren sich jedoch auf Langzeit-SLAM und sind nicht auf die Echtzeitanwendung im Kontext von LiDAR-Odometrie. Im Vergleich zu konventionellen LiDAR-Odometrie-Methoden wie KISS-ICP [47] und MAD-ICP [55] oder LiDAR-Inertial-Odometrie-Methoden wie RKO-LIO [56] schneidet die entwickelte Methode auf dem MulRan [57] und unserem eigens aufgenommenen Datensatz *Odyssey* deutlich besser ab. Auf dem KITTI-Datensatz [43] liefert die Methode lediglich vergleichbare Ergebnisse. Eine Publikation der Methode ist angestrebt.

1.2.4.6. Untersuchungen zu LiDAR Clustering

Des Weiteren wurde, wie im Projektantrag beschrieben, das *Clustering* von LiDAR-Punktwolken untersucht. Grundsätzlich ist Clustering eine Methode, die im unüberwachten Machine Learning anzusiedeln ist. Ziel ist es, aus einer unsortierten Menge von Datenpunkten Gruppen aus zusammengehörigen Punkten zu identifizieren. Ein Clustering einer LiDAR-Punktwolke kann somit helfen, Punkte, die demselben geometrischen Objekt, wie einem Fahrzeug oder Gebäude, zugeordnet sind, miteinander zu verknüpfen. Da das Clustering nur ein erster Vorverarbeitungsschritt im Verarbeiten der dichten Punktwolken ist, ist eine effiziente Verarbeitung vonnöten. Insbesondere moderne Laserscanner liefern durch die hohe Abtastrate extrem dichte Punktwolken, was die Verarbeitung im Livebetrieb durch den reinen Datendurchsatz erschwert. Dementsprechend wurde ein besonderer Fokus auf die Vorverarbeitung der LiDAR-Punktwolke gelegt. Typischerweise wird hierbei die Größe der Daten durch Sampling-Verfahren, d.h. Verfahren, die eine Untermenge der gemessenen Punkte auswählen, verringert. Hierbei wurden verschiedene Strategien untersucht, sowohl im Hinblick auf Laufzeit als auch auf die Genauigkeit des resultierenden Clusteringergebnisses. Im Zuge einer Masterarbeit in dieser Thematik wurde damit auch der wissenschaftliche Nachwuchs an der UGOE gefördert.

1.2.4.7. Integration der UGOE-Algorithmen in die Live-Anwendung im Fahrzeug

Die entwickelten Algorithmen wurden auch an das Softwaresystem und die Schnittstellen, die im Fahrzeug bei iMAR vorliegen, angepasst. Das Ziel war, dass die Methoden direkt live im Fahrzeug eine Positions- und Orientierungsschätzung anzeigen. Dies wurde zunächst anhand von aufgenommenen Daten entwickelt, und dann im Anschluss in enger Zusammenarbeit mit iMAR auch im Live-Betrieb getestet. Der Fokus hierbei lag auf den beiden an der UGOE entwickelten Methoden zur Integration von Kartendaten in die Odometrie. Insbesondere die Straßennetzintegration basierend auf reinen IMU-Daten wurde hierbei im Detail betrachtet, da diese aufgrund der laufzeittechnisch schnellen Input-Odometrie effizient eingesetzt werden konnte.

1.2.4.8. Nacht des Wissens ins Göttingen

In Göttingen fand am 21.06.2025 die *Nacht des Wissens* statt, bei der Wissenschaftseinrichtungen der gesamten Stadt Forschungsprojekte usw. öffentlichkeitswirksam präsentierten und zu Diskussionen einluden. Hier wurde auch das Forschungsprojekt OKULAR vorgestellt. Da ein großer Fokus der Forschungsarbeit der UGOE im Projekt auf LiDAR-Daten liegt, wurden verschiedene Angebote um LiDAR gezeigt. Dies wurde weiterhin mit einem Poster kombiniert, in dem die bisherige Forschungsarbeit der UGOE vorgestellt und zusammengefasst wurde. Insgesamt wurde die technische Präsentation über das Poster hinaus dreigeteilt: Ein interaktiver Stand mit einem mobilen Roboter, der von Besuchern gesteuert werden konnte, demonstrierte das Konzept von Simultaneous Localization and Mapping (SLAM) anhand von einem auf dem Roboter montierten Single-Layer-LiDAR. Der Roboter bewegte sich in einem abgegrenzten Stand aus Miniaturhäusern, die von den Besuchern mit dem Roboter „kartografiert“ werden konnten. Des Weiteren wurde eine Demonstration mit einem 16-Layer LiDAR vor Ort aufgebaut. Eine Visualisierung der Daten auf einem entsprechend großen Monitor zeigte den Besucherinnen und Besuchern, wie sie von intelligenten Fahrzeugen „gesehen“ werden. Dadurch, dass der LiDAR-Sensor die Umgebung des Standes und somit auch die Besucher selbst live aufgenommen und visualisiert hat, konnte direkt mit den Sensordaten interagiert werden. Drittens wurde ein „interaktives Video“ mit den von iMAR im Projekt aufgenommenen Daten aufgebaut, bei dem die Besucher die Kamerasteuerung durch eine LiDAR-Punktwolke von verschiedenen Fahrten in urbanem und suburbanem Gelände übernehmen konnten, um sich einen Eindruck über die Art der Daten zu verschaffen.

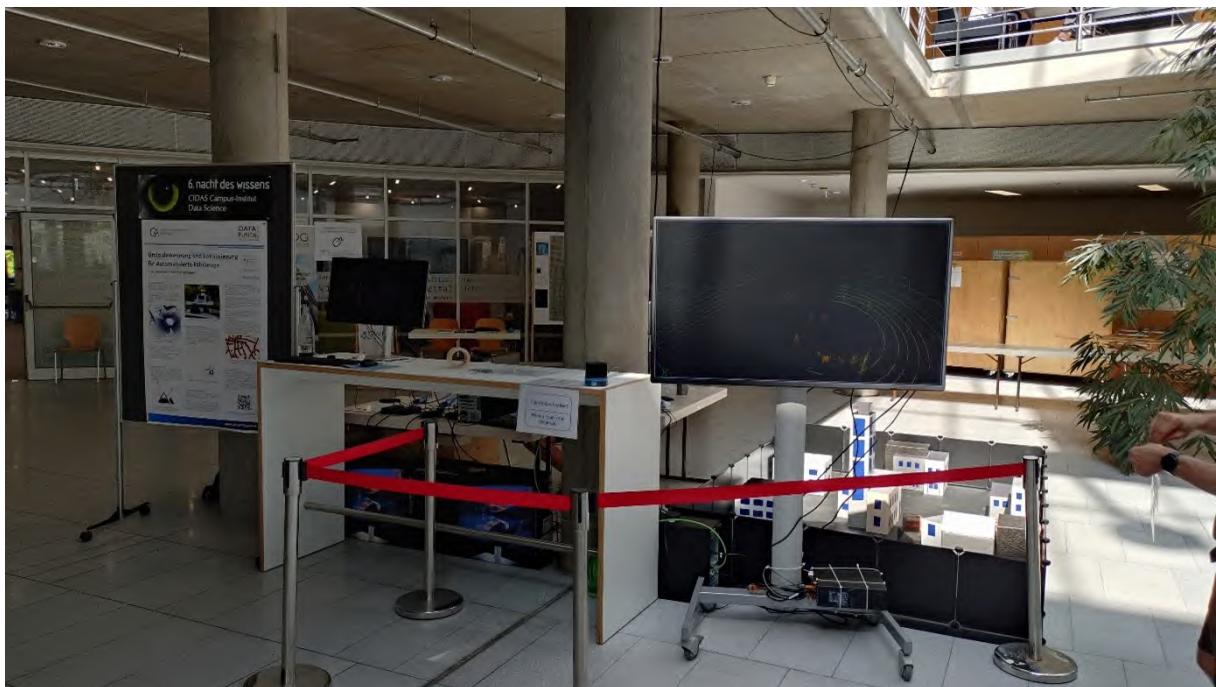


Abbildung 82: Präsentation des Projekts OKULAR bei der Nacht des Wissens in Göttingen.

1.3. Gegenüberstellung zu den vorgegebenen Zielen

Im Folgenden werden die im Vorhaben erzielten Ergebnisse den im Antrag definierten Zielen gegenübergestellt und hinsichtlich ihres Erreichungsgrades bewertet.

1.3.1. iMAR Navigation GmbH

Die im Vorhaben formulierten Ziele konnten in allen zentralen Bereichen erreicht werden. Ausgangspunkt war die im Antrag definierte Zielsetzung, eine modulare Sensorplattform aufzubauen, umfangreiche Datensätze in unterschiedlichen Verkehrsszenarien zu erfassen und darauf aufbauend Verfahren zur Relativ- und Absolutortung zu entwickeln. Diese Vorgaben wurden im Projektverlauf umgesetzt und durch praktische Erprobungen in verschiedenen Umgebungen validiert.

Die hochintegrierte Sensorplattform wurde wie vorgesehen realisiert und ermöglichte die konsistente Erfassung der relevanten Sensordaten unter realen Betriebsbedingungen. Die daraus gewonnenen Datensätze decken die vorgesehenen strukturellen und dynamischen Szenarien ab – einschließlich innerstädtischer Bereiche, Wohngebiete, ländlicher Strecken sowie GNSS-teilweise oder vollständig abgeschatteter Abschnitte. Diese Varianz bildete die Grundlage für die algorithmische Weiterentwicklung und Bewertung.

Die im Projekt entwickelten Verfahren zur Relativortung erfüllen in weiten Bereichen die Zielsetzungen auf funktionaler Ebene hinsichtlich Stabilität, Reproduzierbarkeit und Driftverhalten. Gleichzeitig konnten Randbereiche identifiziert werden, in denen die Verfahren derzeit an ihre Grenzen stoßen. Die entwickelten Methoden wurden in verschiedenen Szenarien eingesetzt und zeigen ein konsistentes Verhalten über unterschiedliche Umgebungsbedingungen hinweg. Die darauf aufbauenden Ansätze zur Absolutortung orientieren sich an den Zieltvorgaben und wurden in den vorgesehenen Testumgebungen erprobt, sodass die angestrebte vollständige Trajektorienrekonstruktion realisiert werden konnte.

Die vorgesehenen Validierungsaktivitäten wurden durchgeführt und lieferten eine belastbare Einschätzung der Leistungsfähigkeit der entwickelten Methoden. Insgesamt zeigen die Auswertungen, dass die Verfahren im angestrebten Genauigkeitsbereich arbeiten und sich für die adressierten Einsatzbedingungen eignen. Der erreichte Technologiereifegrad wird mit TRL 6 abgeschätzt (Prototyp in Einsatzumgebung).

Zusammenfassend lässt sich festhalten, dass die im Projekt formulierten Ziele umgesetzt wurden und dass die erarbeiteten Methoden und Ergebnisse den im Antrag definierten Anforderungen entsprechen. Darüber hinaus wurde ein technologischer Ausgangspunkt geschaffen, der der iMAR Navigation GmbH eine solide Basis für weiterführende Entwicklungen und Anwendungen im Bereich der Lokalisierung bietet.

1.3.2. Valeo Schalter und Sensoren GmbH

Valeo konzentrierte sich in diesem Projekt auf die Erforschung und Entwicklung von Methoden zur Fusion von Daten aus fahrzeugfesten Sensoren mit Informationen aus hochgenauen Karten.

Die Integration von Kartendaten in das Umfeldmodell wurde erfolgreich realisiert. Die verschiedenen Funktionalitäten, die sich aus deren Nutzung ergeben, wurden implementiert und in Testfahrten evaluiert. Im Detail ermöglicht das Umfeldmodell eine kartengestützte Bodenerkennung in Punktwolkensensoren, ein Modell zur kartengestützten Definition einer dynamischen „Region of Interest“, eine kartengestützte Auswahl der Bewegungsmodelle sowie die Fusion von Spurinformationen zur Erkennung und Verfolgung von Spurmarkierungen, was die Punktzuweisung und somit das Punktclustering unterstützt.

Hierzu wurde planmäßig ein Versuchsträger (VW ID.4) konfiguriert. Die vorgesehenen Testfahrten innerhalb und außerhalb der Kartengebiete wurden über die gesamte Projektlaufzeit durchgeführt, was die Validierung der entwickelten Algorithmen ermöglichte. Darüber hinaus wurde das notwendige 3D-Tooling zur Visualisierung und zum Debugging erstellt und getestet. Des Weiteren hat Valeo Karten sowie schwer zu modellierende Fehler analysiert und automatische Korrekturfunktionen entwickelt, um diese zu beheben.

Zusammenfassend kann festgestellt werden, dass die im Projekt formulierten Ziele erfolgreich bearbeitet und dem Antrag entsprechend umgesetzt wurden. Insgesamt konnte eine reproduzierbare Integration von Karten- und Sensordaten im Umfeldmodell, im Bereich der Autobahn und mit Technologiereifegrad 6 (Prototyp in Einsatzumgebung) erreicht werden. Die Verwendung der im Projekt entwickelten Algorithmen in zukünftigen Projekten und Produkten wird im Kapitel 4 (Voraussichtlicher Nutzen) beschrieben.

1.3.3. DLR

Kern der Arbeiten am DLR war die Implementation und Integration einer umfeldsensorbasierten und zu GNSS komplementären Positionierungslösung und die Bewertung dieser Lösung im automatisierten Fahrbetrieb. Nach Evaluation der zur Verfügung stehenden Sensoren (Kamera, LiDAR, Radar, INS, GNSS) und Grundlagenmethoden (SLAM, Visuelle Odometrie) wurde die Idee einer LiDAR-basierten Lösung weiterverfolgt. Im Kern setzt die implementierte Methode auf LiDAR-SLAM und dessen Erweiterungen auf. Grenzfälle der optischen Lokalisierung sind vorrangig Drift bei komplett fehlender Absolutreferenz, Positionssprünge durch Fusion von Daten mit ungenauer bzw. fehlerhafter Unsicherheitsschätzung, sowie Positionssprünge durch fehlerhafte Registrierung von Sensor- mit Umgebungsdaten. Für alle Punkte wurden im Projekt Lösungen erarbeitet: Absolutpositionierung durch Einbeziehen von GNSS und Kartierung aus mehreren Befahrungen, verbesserte Schätzungen von Unsicherheiten im Vergleich zu Filterverfahren, sowie semantische Segmentierung von Daten zur Vermeidung von der fälschlichen Registrierung mit dynamischen Umgebungsmerkmalen. Insgesamt konnte eine reproduzierbare stabile Positionslösung für urbane Gebiete mit Technologiereifegrad 5 (Versuchsaufbau in Einsatzumgebung) erstellt werden. Die Lösung ist echtzeitfähig und mit den Ausgaben anderer Positionierungssysteme (Datenformat NovAtel INSPVA) kompatibel. Hierdurch konnte die Lösung für den automatisierten Fahrbetrieb qualifiziert werden, und ist letztendlich ein Bestandteil der Versuchsanlagen geworden. Die Lösung wird für Versuche und Demonstrationen neuerer Projekte erfolgreich eingesetzt. Die erwarteten Wechselwirkungen zwischen Positionierung und Regelung haben bisher nicht zu einem instabilen Verhalten geführt. Zur Bewertung von Fahr-

zeugpositionierung und Umfeldwahrnehmung wurden ein mobiles Referenzsystem aufgebaut und Verfahren zur automatisierten Kalibrierung entwickelt.

Die Sensorplattform des Partners iMAR wurde in Versuchen auf einem partnereigenem Fahrzeug erprobt. Zur weiterführenden Evaluation wurden gemeinsame Versuche in Braunschweig durchgeführt, bei denen die Infrastruktursensorik auch für das iMAR-Fahrzeug und dessen Sensorplattform Referenzdaten erzeugt hat. Selbiges gilt auch für das Fahrzeug des Partners Valeo. Auf die Veröffentlichungen mit Projektbezug wird in Abschnitt 6 sowie im Beitragsteil unter 1.2.3 verwiesen.

1.3.4. Universität Göttingen

Die Arbeit an der Universität Göttingen konzentrierte sich auf das Problem der genauen und robusten Positionsschätzung mithilfe von LiDAR-Daten, insbesondere im Kontext von LiDAR-Odometrie und SLAM. Dabei wurden sowohl kartengestützte Ansätze als auch Methoden ohne vorherige Karteninformation, also klassische LiDAR-Odometrie- und SLAM-Verfahren, entwickelt. Im Rahmen dieser Forschung sind zwei wissenschaftliche Publikationen veröffentlicht worden. Die erste Veröffentlichung [42] befasst sich mit der merkmalsbasierten Lokalisierung und dem Ziel, eine kompakte Kartenrepräsentation in Form eines Gauß-Mischmodells zu erzeugen. Die zweite Publikation [58] widmet sich der Integration von niedrig aufgelösten Kartendaten. Da nur eine begrenzte Menge an hochauflösten Kartendaten verfügbar war, wurden diese durch niedrig aufgelöste Karten ersetzt. Letztere bieten den Vorteil einer höheren Verfügbarkeit und einer günstigeren Relation zwischen Informationsgehalt und Speicherbedarf. Auch wenn bislang keine quantitative Evaluation der in Abschnitt 1.2.4.3 beschriebenen Methode mit hochauflösten Karten vorliegt, ist das Verfahren prinzipiell auch auf solche Kartendaten anwendbar.

Insgesamt wurden die im Projekt formulierten Ziele erreicht und die erarbeiteten Methoden und Ergebnisse entsprechen den im Antrag definierten Anforderungen. Es wurden interessante wissenschaftliche Erkenntnisse im Bereich der (kartengestützten) Positionierung gewonnen, die Ausgangspunkt für weitere Untersuchungen und Entwicklungen sein werden.

2. Wichtigste Positionen des zahlenmäßigen Nachweises

Die Positionen und Nachweise werden von den jeweiligen Projektpartnern gesondert eingereicht.

3. Notwendigkeit und Angemessenheit der geleisteten Arbeit

Die abgerufenen finanziellen Mittel wurden ausschließlich für das Projekt OKULAR verwendet. Die geleisteten Arbeiten werden in diesem Bericht beschrieben und dort inhaltlich und der Zielsetzung entsprechend motiviert. Die Notwendigkeit und Angemessenheit ist damit impliziert.

4. Voraussichtlicher Nutzen, insbesondere die Verwertbarkeit des Ergebnisses im Sinne des fortgeschriebenen Verwertungsplans

4.1. iMAR Navigation GmbH

Hohe Automatisierungsgrade bei Landfahrzeugen erfordern grundsätzlich eine zuverlässige Absicherung der GNSS-basierten Lokalisierung. Die im Rahmen dieses Projekts entwickelten technologischen Kompetenzen sowie die in den Feldversuchen gewonnenen Erkenntnisse bilden eine wesentliche Grundlage für die mittel- bis langfristige Realisierung kommerzieller Lösungen im Bereich der präzisen Fahrzeuglokalisierung unter GNSS-denied-Bedingungen. Die entwickelten Verfahren und Systemkonzepte lassen sich mit vergleichsweise geringem Anpassungsaufwand auf unterschiedliche Anwendungsfelder und Einsatzszenarien übertragen. Dies betrifft insbesondere die Nutzung in szenarienbasierten Testumgebungen sowie die Erweiterung bestehender Sensor-datenfusionssysteme um LiDAR-basierte Lokalisierungskomponenten. Eine quantitative Bewertung des wirtschaftlichen Potenzials, insbesondere im Automotive-Sektor, ist zum aktuellen Zeitpunkt aufgrund der allgemeinen Marktdynamik und der wirtschaftlichen Rahmenbedingungen nicht belastbar möglich. Die im Fachpublikum erzielte positive Rückmeldung zur in [59] dargestellten Methodik zur Verifikation von INS-Lösungen unter GNSS-denied-Bedingungen mithilfe von multimodalen Lokalisierungssystemen bestätigt die Relevanz und Aktualität des gewählten Forschungsansatzes. Auf Basis dieser Ergebnisse wird eine Weiterführung und Vertiefung der Arbeiten in nachfolgenden FuE-Vorhaben des Unternehmens angestrebt.

4.2. Valeo Schalter und Sensoren GmbH

Im Verlauf des Projekts OKULAR wurden in Arbeitspaket 6 mehrere Schlüsselprodukte und -komponenten entwickelt und implementiert, die eine hohe strategische Bedeutung für die zukünftige Entwicklungsarbeit und Produktpalette von Valeo besitzen. Diese Ergebnisse stellen eine wesentliche Bereicherung für die internen Entwicklungsprozesse dar und sind direkt in verschiedene zukünftige Projekte und Serienentwicklungen integrierbar. Die folgenden Verwertungsoptionen werden dabei als besonders relevant hervorgehoben:

Integration der Visualisierung und Kartendaten als Referenz

- **Eingliederung der Visualisierung in den Standard-Entwicklungsprozess:** Die im Projekt erstellte, hochauflösende Visualisierungskomponente zur Darstellung und Analyse von HD-Karteninformationen wurde erfolgreich in den Standard-Entwicklungsprozess von Valeo für Systeme, die mit High Definition (HD) Karten arbeiten, integriert. Dies ermöglicht eine effizientere Validierung und Fehleranalyse in der frühen Entwicklungsphase.
- **Standardreferenz für Fahrten im Bereich der A81:** Die im Rahmen des Projekts generierten und validierten hochpräzisen Kartendaten, insbesondere für den Bereich der

Autobahn A8, dienen zukünftig als verlässliche und qualitätsgesicherte Standardreferenz für Validierungs- und Testfahrten. Diese Referenzdatensätze sind essenziell für die Bewertung der Genauigkeit und Robustheit neu entwickelter Fahrerassistenzsysteme.

Entwicklung und Nutzung von Tooling zur Datenverbesserung

- **Automatisierte Annotation und Machine Learning Integration:** Es wurde ein spezifisches Tooling zur Verbesserung und Qualitätssicherung von Kartendaten entwickelt. Dieses Tool wird nun sukzessive für die automatisierte Annotation von Sensordaten und deren Einbettung in die internen Machine Learning (ML) Pipelines eingesetzt. Die kontinuierliche Weiterentwicklung dieses Tools zielt darauf ab, die Effizienz der Datenverarbeitung und die Qualität der für das Training von ML-Modellen verwendeten Daten signifikant zu steigern.

Das Fahrspurmodell und die Einbettung in das Umfeldmodell als zentrales Ergebnis

- **Kernresultat: Fahrspurmodell und Kartendatenintegration:** Eines der wichtigsten und für Valeo strategisch wertvollsten Resultate des Projekts ist das entwickelte Fahrspurmodell sowie dessen tiefgreifende Einbettung der Kartendaten in das zentrale Umfeldmodell (Environmental Model).
- **Funktion als zusätzlicher virtueller Sensor:** Während der Entwicklungsphase konnte erfolgreich nachgewiesen werden, dass die integrierten Kartendaten maßgeblich zur Stabilisierung und zur erhöhten Genauigkeit der Lokalisierung und der Erfassung von Objekten, wie beispielsweise erfassten Fahrzeugen, beitragen können. Das integrierte Kartendatenmodul wurde als Standard-Modellkomponente in das Umfeldmodell aufgenommen. In der weiteren Entwicklung dient es als ein zusätzlicher, redundanter und hochpräziser virtueller Sensor.
- **Zukunftssicherheit durch duale Modellarchitektur:** Speziell die Entwicklung eines Modells, das sowohl mit Onboardsensorik-Daten als auch mit Kartendaten effektiv arbeiten kann, gewährleistet die Robustheit und Skalierbarkeit der Lösung. Diese Architektur macht die Arbeit auch für zukünftige Anwendungsfälle und Weiterentwicklungen ohne die zwingende Verfügbarkeit von HD-Kartendaten geeignet (z.B. in Regionen ohne Kartendatenabdeckung oder bei Ausfall der Kartenfunktionalität).

Potenzial für zukünftige Entwicklungen und Folgeprojekte

- **Generation eigenständiger Karten:** Das entwickelte Umfeldmodell wurde in initialen Machbarkeitsstudien erfolgreich für die eigenständige Generierung von Karteninformationen und Attributen aus den erfassten Sensordaten getestet. Ein Beispiel ist in Abbildung 83 zu finden.
- **Enrichment von Low Definition Karten:** Eine zentrale zukünftige Verwertungsmöglichkeit, die in potentiellen Folgeprojekten vertieft werden sollte, ist die Kombination dieser

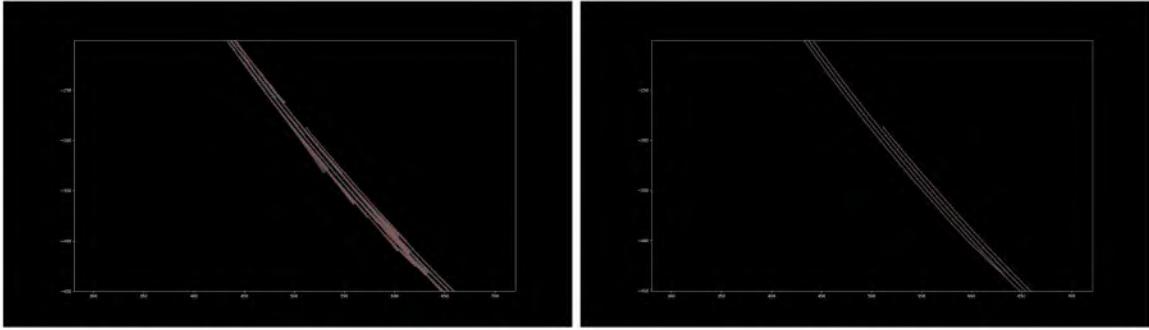


Abbildung 83: Die Abbildung zeigt alle Spuren über alle Zeitschritte, damit auch die initialen Frames die Fehlerbehaftete Input Linien beinhalten, die zweite Abbildung zeigt die durch das Catmul-Rom Spline Model gefilterten Segmente. Hier wird eine Zufahrt auf die Autobahn und eine Spur Zusammenführung abgedeckt.

generierten hochpräzisen Informationen mit bestehenden Low Definition Kartenformaten, wie beispielsweise OpenDrive. Ziel wäre das sogenannte Enrichment (Anreicherung) dieser Karten mit dynamischen und präziseren Attributen. Dies ist insbesondere in Kombination mit den komplementären Arbeiten der anderen Projektpartner von großem Interesse, um eine interoperable und umfassende Lösung zu schaffen.

4.3. DLR

Die Verfahren zur LiDAR-basierten Lokalisierung erfordern die Erstellung von Karten zur Registrierung, und dabei die Sicherung der Kartenqualität im Hinblick auf Vollständigkeit, Aktualität und geodätischer Genauigkeit. Bei Skalierung von typischen SLAM-Verfahren hin zu größeren Gebieten zeigt sich, dass die erforderliche Datenmenge für die Karten die Kapazität von Fahrzeugrechnern übersteigen kann, zudem ist es nicht zwingend erforderlich, dass jedes Fahrzeug die Umgebung selbst kartiert. Hier arbeitet das DLR aktiv an Verfahren zur verteilten Kartierung durch Fahrzeugflotten sowie deren serverseitiger Datenakkumulation und Kartenbereitstellung [14, 30]. Die Idee ist, dass zukünftige Fahrzeuge ihre Sensordaten mit einem Dienst teilen, welcher kontinuierlich aktualisierte Karten bereitstellt. Vorteile sind dabei die statistische Aufhebung des Positionsrauschens durch vielfach redundante Befahrung derselben Gebiete unterschiedlicher Fahrzeuge, die Möglichkeit zur großflächigen Erfassung der Umgebung, sowie die Reduktion der in den Fahrzeugen benötigten Datenmengen. Neben der Möglichkeit zur genaueren Positionierung ergeben sich durch einen derartigen Kartendienst Mehrwerte für weitere Nutzer abseits automatisierter Fahrzeuge, beispielsweise im Bereich der Instandhaltung des Straßenraums oder der Erstellung hochgenauer und aktueller 3D-Geländemodelle. Durch die Mehrwerte wird die Attraktivität und Akzeptanz vernetzter Fahrzeuge weiter erhöht. Das DLR strebt die Fortsetzung dieses Themas im Rahmen weiterer Projekte an, u.a. durch datenraumbezogene Projekte als Nachfolge der *Gaia-X 4 Future Mobility* Projektfamilie.

Seit 2024 ist die LiDAR-gestützte Positionierung in die Forschungsträger (Straßenfahrzeuge) des DLR-Instituts integriert, wodurch weitere Vorhaben im Bereich des automatisierten und

vernetzten Fahrens bereits profitiert haben. Zu erwähnen sind hier u.a. *Gaia-X 4 AGEDA* (BMWE, Fkz. 19S22004N) und *MAD Urban* (BMWE, Fkz. 01ME22001A) mit bereits abgeschlossenen Fahrerdemonstrationen. Das Verfahren wird in Zukunft weiterentwickelt und in entsprechenden Projekten genutzt werden. Perspektivisch ergeben sich dadurch hochgenaue Positionierungs- und Spurhalteassistenzsysteme für erweiterte Betriebsdomänen. Neben dem urbanen Raum (z.B. Kreuzungen, Straßen mit fehlender und mehrdeutiger Markierung) ist durch die Kompensation von GNSS-Positionsausfällen auch eine Erweiterung in Tunnel, Parkhäuser usw. gegeben. Insgesamt ist die Erweiterung der Betriebsdomäne eine wesentliche Säule der strategischen Ausrichtung am Institut.

Die mobile Road Site Unit dient in weiteren Vorhaben nicht nur als Referenzmesssystem, sondern wird auch zur Echtzeitkommunikation mit den Fahrzeugen für Experimente in den Bereichen *Collective Perception* und *Managed Automated Driving* eingesetzt. Hier zeigt sich durch die flexible Einsetzbarkeit ein direkter Mehrwert in Relation zu den bisherigen größeren und stationären Anlagen.

Die im Rahmen des Projekts erzeugten HD-Karten im Raum Braunschweig [11, 12] haben ein weiteres hohes Verwertungspotenzial. Sie ermöglichen zur Zeit die Umsetzung eines prototypischen ÖPNV-Betriebs nach SAE Level 4 / AFGBV im Rahmen des Vorhabens *IMoGer* (BMV, Fkz. 45AVF7A011) bis Ende 2027. Durch die öffentliche Zugänglichkeit der Daten profitieren zudem weitere Nutzer von den erhobenen Daten. Die Stadt Braunschweig zeigt hier entsprechendes Nutzungsinteresse.

Neben der Publikation wissenschaftlicher Lösungsansätze [35] werden die Themen aus dem Projekt aktiv auf Messen und Konferenzen diskutiert (im Projektzeitraum u.a. auf der *IAA 2025* (München) und der *ICITT 2025* (Amsterdam)). So sollen weitere Interessenten für das Thema gewonnen werden. Ein weiterer Baustein der wissenschaftlichen Arbeit am DLR ist die Förderung des wissenschaftlichen Nachwuchses. Hierzu laufen aktuell (bis ca. Frühjahr 2026) zwei studentische Abschlussarbeiten zu den Themen Punktfolkensegmentierung (HS Merseburg) und Bewertung der Kartierungsqualität (TH Lübeck).

4.4. Universität Göttingen

Im Rahmen des Projektes wurde die in Abschnitt 1.2.4.3 beschriebene Methode auf der *European Conference on Mobile Robots (ECMR) 2025* veröffentlicht. Neben der Präsentation auf der Konferenz wurde die Methode zusätzlich in dem angegliederten Workshop präsentiert und diskutiert. Auch der Datensatz aus Abschnitt 1.2.4.4 wurde auf der ECMR bereits in einer Poster-Session vorgestellt. Die Veröffentlichung des gesamten Datensatzes ist zur Zeit in Arbeit und für die nahe Zukunft geplant. Die in Abschnitt 1.2.4.1 beschriebene Methode wurde auf der *Combined SDF and MFI Conference 2023* vorgestellt und veröffentlicht. Eine Veröffentlichung der in Abschnitt 1.2.4.5 beschriebenen Methode ist geplant. Die Erkenntnisse im Bereich der Lokalisierung werden auch in Zukunft als Basis für weitere wissenschaftliche Forschungsaktivitäten dienen. Hierbei ist besonders eine Fortsetzung der in Abschnitt 1.2.4.2 beschriebenen Methode zu nennen, welche ein starkes Potential für eine günstige und drift-freie Lokalisierung verspricht.

Für die Förderung des wissenschaftlichen Nachwuchses wurden mehrere Abschlussarbeiten im Bereich der Lokalisierung betreut. Diese beinhalten

- die Registrierung von LiDAR-Scan mithilfe von Gauß-Wassersteindistanzen, die als Grundlage für die Publikation [42] diente,
- die Untersuchung von Clustering-Algorithmen auf LiDAR-Daten,
- die Berücksichtigung von semantischen Information zur Verbesserung von LiDAR-Odometrie sowie
- die Berücksichtigung von Reflektivitäts-Information zur Verbesserung von LiDAR-Odometrie

Durch die im Projekt gesammelten Erfahrungen im Bereich der Lokalisierung konnte dieses Thema in den Lehrveranstaltungen vertieft behandelt werden. Dazu zählen sowohl ein stärkerer Fokus auf fundamentale Algorithmen zur Positionsbestimmung in Vorlesungen und Seminaren als auch neu entwickelte Aufgabenstellungen für praktische Arbeiten mit Robotern.

5. Während der Durchführung des Vorhabens dem ZE bekannt gewordener Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen

Eine verwandte Arbeit zu der in Abschnitt 1.2.4.3 beschriebenen Methode wurde kurz nach der Veröffentlichung des preprints der hier beschriebenen Methode veröffentlicht. Ein fundamentaler methodischer Unterschied besteht darin, dass [51] eine Pose-Graph-Optimierung verwendet, um zwei Schätzungen miteinander zu fusionieren, während die im Projekt OKULAR entwickelte Methode [58] die Fusion über einen Complementary-Filter realisiert. Unter [60] ist eine verwandte Arbeit zu der von uns beschriebenen Methode in Abschnitt 1.2.4.4 publiziert worden.

6. Erfolgte oder geplante Veröffentlichungen des Ergebnisses

Die beiden in 1.2.4.1 und 1.2.4.3 beschriebenen Methoden wurden auf Fachkonferenzen publiziert [58, 42]. Die meisten Arbeiten an dem Odyssey-Datensatz (Abschnitt 1.2.4.4) wurden abgeschlossen. Eine Publikation ist in naher Zukunft geplant. Eine erste Version der in Abschnitt 1.2.4.5 beschriebenen Methode wurde bereits veröffentlicht [61]. Diese soll in naher Zukunft aktualisiert und auf einer Fachkonferenz oder in einer Fachzeitschrift veröffentlicht werden. Als Teil der Öffentlichkeitsarbeit wurden die Ergebnisse des Projekts in einem gemeinsamen Abschlussvideo¹ zusammengefasst.

Des Weiteren wurde Rahmen des Vorhabens eine wissenschaftliche Publikation mit dem Titel „Concept for System Performance Verification of INS/GNSS Solutions within GNSS-denied

¹<https://youtu.be/ZiVMJZsKAmA>

Environments“ auf der *DGON-ISA-Konferenz 2024* in Braunschweig präsentierte [59]. Die Arbeit adressiert die methodische Herausforderung der Validierung von Navigationssystemen unter eingeschränkter oder fehlender GNSS-Verfügbarkeit und schlägt hierzu ein konsistentes, GNSS-unabhängiges Verifikationsverfahren vor, siehe 1.2.1.3.

Das DLR hat neben einigen projektübergreifenden Publikationen die Methode zur Segmentierung von Fahrstreifen aus Abschnitt 1.2.3.5 unter [35] publiziert, weitere Publikationen mit Themenbezug sind geplant. Die Kartierungen am Schwarzen Berg in Braunschweig wurden unter [11] und [12] publiziert. Sofern anwendbar, werden unter den angegebenen Quellen Aktualisierungen zur Verfügung gestellt.

Literaturverzeichnis

- [1] Cesar Cadena et al. “Past, Present, and Future of Simultaneous Localization and Mapping: Toward the Robust-Perception Age”. In: *IEEE Transactions on Robotics* 32.6 (2016), pp. 1309–1332. DOI: [10.1109/TRA.2016.2624754](https://doi.org/10.1109/TRA.2016.2624754).
- [2] Wolfram Burgard, Oliver Brock, and Cyrill Stachniss. “Map-Based Precision Vehicle Localization in Urban Environments”. In: *Robotics: Science and Systems III*. 2008, pp. 121–128.
- [3] Markus Schreiber, Carsten Knöppel, and Uwe Franke. “LaneLoc: Lane marking based localization using highly accurate maps”. In: *2013 IEEE Intelligent Vehicles Symposium (IV)*. 2013, pp. 449–454. DOI: [10.1109/IVS.2013.6629509](https://doi.org/10.1109/IVS.2013.6629509).
- [4] Nico Engel, Vasileios Belagiannis, and Klaus Dietmayer. “Attention-based Vehicle Self-Localization with HD Feature Maps”. In: *2021 IEEE International Intelligent Transportation Systems Conference (ITSC)*. 2021, pp. 76–83. DOI: [10.1109/ITSC48978.2021.9564726](https://doi.org/10.1109/ITSC48978.2021.9564726).
- [5] Fabian Poggenhans, Niels Ole Salscheider, and Christoph Stiller. “Precise Localization in High-Definition Road Maps for Urban Regions”. In: *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. 2018, pp. 2167–2174. DOI: [10.1109/IROS.2018.8594414](https://doi.org/10.1109/IROS.2018.8594414).
- [6] Wei-Chiu Ma et al. “Exploiting Sparse Semantic HD Maps for Self-Driving Vehicle Localization”. In: *2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. 2019, pp. 5304–5311. DOI: [10.1109/IROS40897.2019.8968122](https://doi.org/10.1109/IROS40897.2019.8968122).
- [7] Henning Lategahn and Christoph Stiller. “Vision-Only Localization”. In: *IEEE Transactions on Intelligent Transportation Systems* 15.3 (2014), pp. 1246–1257. DOI: [10.1109/TITS.2014.2298492](https://doi.org/10.1109/TITS.2014.2298492).
- [8] Ioan Andrei Bârsan et al. *Learning to Localize Using a LiDAR Intensity Map*. 2020. arXiv: [2012.10902 \[cs.CV\]](https://arxiv.org/abs/2012.10902). URL: <https://arxiv.org/abs/2012.10902>.

- [9] Olga Vysotska and Cyrill Stachniss. “Improving SLAM by exploiting building information from publicly available maps and localization priors”. In: *PFG–Journal of Photogrammetry, Remote Sensing and Geoinformation Science* 85.1 (2017), pp. 53–65.
- [10] Tixiao Shan et al. “LIO-SAM: Tightly-coupled Lidar Inertial Odometry via Smoothing and Mapping”. In: *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. IEEE. 2020, pp. 5135–5142.
- [11] Michael Scholz et al. *OpenDRIVE road network dataset of Schwarzer Berg in Brunswick*. 2025. DOI: [10.5281/zenodo.15395839](https://doi.org/10.5281/zenodo.15395839).
- [12] Michael Scholz et al. *Road space point cloud of Schwarzer Berg in Brunswick (excerpt)*. 2025. DOI: [10.5281/zenodo.15527621](https://doi.org/10.5281/zenodo.15527621).
- [13] Kenji Koide, Jun Miura, and Emanuele Menegatti. “A portable three-dimensional LIDAR-based system for long-term and wide-area people behavior measurement”. In: *International Journal of Advanced Robotic Systems* 16.2 (2019). DOI: [10.1177/1729881419841532](https://doi.org/10.1177/1729881419841532). URL: https://github.com/koide3/hdl_localization.
- [14] Franz Andert et al. “Semantic LiDAR Point Cloud Mapping and Cloud-Based SLAM for Autonomous Driving”. In: *2025 IEEE/ION Position, Location and Navigation Symposium, PLANS 2025*. 2025, pp. 853–860. DOI: [10.1109/PLANS61210.2025.11028497](https://doi.org/10.1109/PLANS61210.2025.11028497).
- [15] Matthias Nichting and Thomas Lobig. “ADORe – Automated Driving Open Research”. In: *EclipseCon*. 2023. URL: <https://elib.dlr.de/199550/>.
- [16] Giovanni Lucente et al. “DeepGame-TP: Integrating Dynamic Game Theory and Deep Learning for Trajectory Planning”. In: *IEEE Open Journal of Intelligent Transportation Systems* 5 (2024), pp. 873–888. DOI: [10.1109/OJITS.2024.3515270](https://doi.org/10.1109/OJITS.2024.3515270).
- [17] Anas Abulehia, Reza Dariani, and Julian Schindler. “Optimal Velocity Model Based CACC Controller for Urban Scenarios”. In: *10th International Conference on Vehicle Technology and Intelligent Transport Systems, VEHITS*. 2024. DOI: [10.5220/0012650200003702](https://doi.org/10.5220/0012650200003702).
- [18] Kenji Koide. “small_gicp: Efficient and parallel algorithms for point cloud registration”. In: *Journal of Open Source Software* 9.100 (Aug. 2024), p. 6948. DOI: [10.21105/joss.06948](https://doi.org/10.21105/joss.06948).
- [19] Mason Woo et al. *OpenGL programming guide: the official guide to learning OpenGL, version 1.2*. Addison-Wesley Longman Publishing Co., Inc., 1999.
- [20] *libOpenDRIVE Viewer Github*. <https://github.com/pageldev/libOpenDRIVE>. Accessed: 2025-11-20.
- [21] Hauke Kaulbersch, Jens Honer, and Marcus Baum. “A Cartesian B-spline vehicle model for extended object tracking”. In: *2018 21st International Conference on Information Fusion (FUSION)*. 2018, pp. 1–5. DOI: [10.23919/ICIF.2018.8455717](https://doi.org/10.23919/ICIF.2018.8455717).
- [22] Yue Wang, Dinggang Shen, and Eam Khwang Teoh. “Lane detection using catmull-rom spline”. In: *IEEE International Conference on Intelligent Vehicles*. Vol. 1. 1998, pp. 51–57.

- [23] Zhijian Qiao et al. “Online monocular lane mapping using catmull-rom spline”. In: *2023 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. 2023, pp. 7179–7186. DOI: [10.1109/IROS55552.2023.10341707](https://doi.org/10.1109/IROS55552.2023.10341707).
- [24] *Sechsstreifiger Ausbau BAB A 7 vom AD Salzgitter bis südl. der AS Bockenem*. https://www.strassenbau.niedersachsen.de/download/59420/Faltblatt_Sechsstreifiger_Ausbau_der_A_7_vom_AD_Salzgitter_bis_suedlich_der_AS_Bockenem_.pdf. Accessed: 2025-11-20.
- [25] Daniel Heß et al. “Fast Maneuver Planning for Cooperative Automated Vehicles”. In: *21st IEEE International Conference on Transportation Systems*. 2018. DOI: [10.1109/ITSC.2018.8569791](https://doi.org/10.1109/ITSC.2018.8569791).
- [26] Franz Andert and Henning Mosebach. “LiDAR SLAM Positioning Quality Evaluation in Urban Road Traffic”. In: *3rd EAI International Conference on Intelligent Transport Systems, INTSYS*. 2019. DOI: [10.1007/978-3-030-38822-5_19](https://doi.org/10.1007/978-3-030-38822-5_19).
- [27] Jörg Schäfer et al. “Fighting Unreliable GNSS with LiDAR: Autonomous Driving. In The Project KoMo:Dnext”. In: *DGON Conf. on Positioning And Navigation for Intelligent Transport Systems*. 2022.
- [28] Martin Magnusson. “The Three-Dimensional Normal-Distributions Transform – an Efficient Representation for Registration, Surface Analysis, and Loop Detection”. PhD thesis. Örebro University, 2009.
- [29] Michael Scholz, Franz Andert, et al. *European Digital Dynamic Mapping (EDDY) – Schlussbericht*. Tech. rep. 2025. DOI: [10.34657/20307](https://doi.org/10.34657/20307).
- [30] Franz Andert et al. “On SLAM as a Service for Self-Driving Cars”. In: *DGON POSNAV, Positioning and Navigation for Intelligent Transport Systems*. 2024.
- [31] Andres Milioto et al. “RangeNet++: Fast and Accurate LiDAR Semantic Segmentation”. In: *IEEE/RSJ Intl. Conf. on Intelligent Robots and Systems (IROS)*. 2019. DOI: [10.1109/IROS40897.2019.8967762](https://doi.org/10.1109/IROS40897.2019.8967762).
- [32] Jens Behley et al. “SemanticKITTI: A Dataset for Semantic Scene Understanding of LiDAR Sequences”. In: *Proc. of the IEEE/CVF International Conf. on Computer Vision (ICCV)*. 2019. DOI: [10.1109/ICCV.2019.00939](https://doi.org/10.1109/ICCV.2019.00939).
- [33] Larissa T. Triess et al. “A Survey on Deep Domain Adaptation for LiDAR Perception”. In: *2021 IEEE Intelligent Vehicles Symposium Workshops (IV Workshops)*. 2021, pp. 350–357. DOI: [10.1109/IVWorkshops54471.2021.9669228](https://doi.org/10.1109/IVWorkshops54471.2021.9669228).
- [34] R. Qi Charles et al. “PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation”. In: *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2017, pp. 77–85. DOI: [10.1109/CVPR.2017.16](https://doi.org/10.1109/CVPR.2017.16).
- [35] Aditya Mushyam, Oliver Böttcher, and Franz Andert. “PCLane: Accurate Lane Localization with LiDAR and abstract data”. In: *3rd IEEE Conference on Artificial Intelligence, CAI 2025*. 2025, pp. 1578–1581. DOI: [10.1109/CAI64502.2025.00281](https://doi.org/10.1109/CAI64502.2025.00281).

- [36] Mikael Persson; Klas Nordberg. “Lambda Twist: An Accurate Fast Robust Perspective Three Point (P3P) Solver”. In: *European Conference on Computer Vision*. 2018. DOI: [10.1007/978-3-030-01225-0_20](https://doi.org/10.1007/978-3-030-01225-0_20).
- [37] Maxime Oquab et al. *DINOv2: Learning Robust Visual Features without Supervision*. 2024. DOI: [10.48550/arXiv.2304.07193](https://doi.org/10.48550/arXiv.2304.07193).
- [38] Mikkel Skov Maarssø et al. “ADORe: Unified Modular Framework for Vehicle and Infrastructure-Based System Level Automation”. In: *International Conference on Vehicle Technology and Intelligent Transport Systems*. 2025. DOI: [10.5220/0013405200003941](https://doi.org/10.5220/0013405200003941).
- [39] P. Biber and W. Strasser. “The normal distributions transform: a new approach to laser scan matching”. In: *Proceedings 2003 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2003) (Cat. No.03CH37453)*. Vol. 3. 2003, 2743–2748 vol.3. DOI: [10.1109/IROS.2003.1249285](https://doi.org/10.1109/IROS.2003.1249285).
- [40] Masashi Yokozuka et al. “LiTAMIN: LiDAR-based Tracking And Mapping by Stabilized ICP for Geometry Approximation with Normal Distributions”. In: *2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. 2020, pp. 5143–5150. DOI: [10.1109/IROS45743.2020.9341341](https://doi.org/10.1109/IROS45743.2020.9341341).
- [41] Masashi Yokozuka et al. “LiTAMIN2: Ultra Light LiDAR-based SLAM using Geometric Approximation applied with KL-Divergence”. In: *2021 IEEE International Conference on Robotics and Automation (ICRA)*. 2021, pp. 11619–11625. DOI: [10.1109/ICRA48506.2021.9560947](https://doi.org/10.1109/ICRA48506.2021.9560947).
- [42] Simon Steuernagel, Aaron Kurda, and Marcus Baum. “Point Cloud Registration based on Gaussian Mixtures and Pairwise Wasserstein Distances”. In: *2023 IEEE Symposium Sensor Data Fusion and International Conference on Multisensor Fusion and Integration (SDF-MFI)*. 2023, pp. 1–8. DOI: [10.1109/SDF-MFI59545.2023.10361440](https://doi.org/10.1109/SDF-MFI59545.2023.10361440).
- [43] Andreas Geiger et al. “Vision meets robotics: The kitti dataset”. In: *The international journal of robotics research* 32.11 (2013), pp. 1231–1237.
- [44] Georgios Floros, Benito van der Zander, and Bastian Leibe. “OpenStreetSLAM: Global vehicle localization using OpenStreetMaps”. In: *2013 IEEE International Conference on Robotics and Automation*. 2013, pp. 1054–1059. DOI: [10.1109/ICRA.2013.6630703](https://doi.org/10.1109/ICRA.2013.6630703).
- [45] Shuxia Gu et al. “A Multi-Position Joint Particle Filtering Method for Vehicle Localization in Urban Area”. In: *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. 2018, pp. 656–662. DOI: [10.1109/IROS.2018.8593781](https://doi.org/10.1109/IROS.2018.8593781).
- [46] Philipp Ruchti et al. “Localization on OpenStreetMap data using a 3D laser scanner”. In: *2015 IEEE International Conference on Robotics and Automation (ICRA)*. 2015, pp. 5260–5265. DOI: [10.1109/ICRA.2015.7139932](https://doi.org/10.1109/ICRA.2015.7139932).
- [47] Ignacio Vizzo et al. “KISS-ICP: In Defense of Point-to-Point ICP – Simple, Accurate, and Robust Registration If Done the Right Way”. In: *IEEE Robotics and Automation Letters* 8.2 (2023), pp. 1029–1036. DOI: [10.1109/LRA.2023.3236571](https://doi.org/10.1109/LRA.2023.3236571).

- [48] Walter T Higgins. “A comparison of complementary and Kalman filtering”. In: *IEEE Transactions on Aerospace and Electronic Systems* 3 (1975), pp. 321–325.
- [49] Matteo Frosi, Veronica Gobbi, and Matteo Matteucci. “OSM-SLAM: Aiding slam with openstreetmaps priors”. In: *Frontiers in Robotics and AI* 10 (2023), p. 1064934.
- [50] Augusto Luis Ballardini et al. “Vehicle localization using 3D building models and point cloud matching”. In: *Sensors* 21.16 (2021), p. 5356.
- [51] Dominik Kulmer et al. “OpenLiDARMap: Zero-Drift Point Cloud Mapping Using Map Priors”. In: *Proceedings of the 11th International Conference on Vehicle Technology and Intelligent Transport Systems - VEHITS*. INSTICC. SciTePress, 2025, pp. 178–188. ISBN: 978-989-758-745-0. DOI: [10.5220/0013405400003941](https://doi.org/10.5220/0013405400003941).
- [52] OpenStreetMap contributors. *Planet dump* retrieved from <https://planet.osm.org>. <https://www.openstreetmap.org>. 2017.
- [53] Giorgio Grisetti et al. “Hierarchical optimization on manifolds for online 2D and 3D mapping”. In: *2010 IEEE International Conference on Robotics and Automation*. IEEE. 2010, pp. 273–278.
- [54] David Droeßel and Sven Behnke. “Efficient continuous-time SLAM for 3D lidar-based online mapping”. In: *2018 IEEE International Conference on Robotics and Automation (ICRA)*. IEEE. 2018, pp. 5000–5007.
- [55] Simone Ferrari et al. “MAD-ICP: It is All About Matching Data – Robust and Informed LiDAR Odometry”. In: *IEEE Robotics and Automation Letters* 9.11 (2024), pp. 9175–9182. DOI: [10.1109/LRA.2024.3456509](https://doi.org/10.1109/LRA.2024.3456509).
- [56] Meher V. R. Malladi et al. *A Robust Approach for LiDAR-Inertial Odometry Without Sensor-Specific Modeling*. 2025. arXiv: [2509.06593 \[cs.RO\]](https://arxiv.org/abs/2509.06593). URL: <https://arxiv.org/abs/2509.06593>.
- [57] Giseop Kim et al. “MulRan: Multimodal Range Dataset for Urban Place Recognition”. In: *2020 IEEE International Conference on Robotics and Automation (ICRA)*. 2020, pp. 6246–6253. DOI: [10.1109/ICRA40945.2020.9197298](https://doi.org/10.1109/ICRA40945.2020.9197298).
- [58] Aaron Kurda et al. “Reducing Drift of Lidar Odometry by Incorporating OpenStreetMap Building Data”. In: *2025 European Conference on Mobile Robots (ECMR)*. 2025, pp. 1–8. DOI: [10.1109/ECMR65884.2025.11163206](https://doi.org/10.1109/ECMR65884.2025.11163206).
- [59] E. v. Hinüber et al. “Concept for System Performance Verification of INS/GNSS Solutions within GNSS denied Environments”. In: *2024 DGON Inertial Sensors and Applications (ISA)*. 2024, pp. 1–16. DOI: [10.1109/ISA62769.2024.10786037](https://doi.org/10.1109/ISA62769.2024.10786037).
- [60] Easton R. Potokar et al. *FORM: Fixed-Lag Odometry with Reparative Mapping utilizing Rotating LiDAR Sensors*. 2025. arXiv: [2510.09966 \[cs.RO\]](https://arxiv.org/abs/2510.09966). URL: <https://arxiv.org/abs/2510.09966>.
- [61] Aaron Kurda, Simon Steuernagel, and Marcus Baum. *Lidar-only Odometry based on Multiple Scan-to-Scan Alignments over a Moving Window*. 2025. arXiv: [2503.21293 \[cs.RO\]](https://arxiv.org/abs/2503.21293). URL: <https://arxiv.org/abs/2503.21293>.