Individueller Schlussbericht der Universität Göttingen

im Projekt

Optische KI-basierte Umfeldwahrnehmung und Lokalisierung für automatisierte Fahrzeuge

Aaron Kurda
Simon Steuernagel

Vorhaben aus dem Programm „Neue Fahrzeug- und Systemtechnologien“
Förderkennzeichen 19A22003

Finanziert von der Europäischen Union
NextGenerationEU

Gefördert durch:
Bundesministerium für Wirtschaft und Energie
aufgrund eines Beschlusses des Deutschen Bundestages

Inhaltsverzeichnis

1 Kurzfassung **3**

1.1 Aufgabenstellung 3

1.2 Wissenschaftlicher und technischer Stand, an den angeknüpft wurde 4

1.3 Ablauf des Vorhabens und Wesentliche Ergebnisse 4

2 Eingehende Darstellung **5**

2.1 Punktwolkenregistrierung mittels Gauß-Wassersteindistanzen 5

2.2 Integration von Straßennetzkarten 7

2.3 Integration von Gebäudekarten 9

2.4 Lidar-Odometrie Datensatz: Odyssey 10

2.5 Graphenbasierte LiDAR-Odometrie 11

2.6 Untersuchungen zu LiDAR Clustering 12

2.7 Integration der UGOE-Algorithmen in die Live-Anwendung 12

2.8 Nacht des Wissens ins Göttingen 12

2.9 Gegenüberstellung zu den vorgegebenen Zielen 14

2.10 Wichtigste Positionen des zahlenmäßigen Nachweises 14

2.11 Notwendigkeit und Angemessenheit der geleisteten Arbeit 14

2.12 Voraussichtlicher Nutzen, insbesondere die Verwertbarkeit des Ergebnisses im Sinne des fortgeschriebenen Verwertungsplans 15

2.13 Während der Durchführung des Vorhabens dem ZE bekannt gewordener Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen 15

2.14 Erfolgte oder geplante Veröffentlichungen des Ergebnisses 16

Literaturverzeichnis **16**

1 Kurzfassung

1.1 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 verschiedensten 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 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

Dieser Bericht ist eine gekürzte und angepasste Version des Berichts des Konsortiums zum Projekt OKULAr [1].

nichtlinearen Zustandsschätzung untersucht, die weit über traditionelle Kalman-Filter-basierte Methoden hinausgehen.

1.2 Wissenschaftlicher und technischer Stand, an den angeknüpft wurde

Relevante Forschungsaktivitäten sind unter anderem im Kontext von *Simultaneous Localization and Mapping* (SLAM) [2] 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, spurrelative Lokalisierung ist so jedoch nur schwierig zu erreichen. Die Verwendung von Karten zur Lokalisierung wird daher im Automotive-Bereich schon länger intensiv erforscht [3]. Beispielweise betrachtet [4] ein Stereo-Kamera System sowie detaillierte Karteninformationen, um eine zentimetergenaue Lokalisierung zu erreichen. Weitere aktuelle Arbeiten basieren auf hochauflösenden Karten, wie zum Beispiel [5, 6, 7], oder verwenden direkt offline aufgenommene Kamera- oder Laserscannerdaten als Karten [8, 9] Die Integration von low-resolution Kartendaten wurde in [10] erforscht. An diese Arbeit konnte mit den in den Abschnitten 2.2 und 2.3 beschriebenen Methoden angeknüpft werden. Auch an existierende Forschungsergebnisse bezüglich der zusätzlichen Integration von inertialer Messtechnik, sogenannter *Lidar Inertial Odometry* (LIO), wurde angeknüft. Eine zentrale Methode ist hier LIO-SAM [11].

1.3 Ablauf des Vorhabens und Wesentliche Ergebnisse

Die Universität Göttingen befasste sich in dem Projekt OKULAr hauptsächlich mit dem Thema der Lidar-Odometry bzw. Lidar-SLAM. Dabei soll auf Basis von von Lidar-Scannern aufgenommenen Punktwolken die Eigenbewegung eines Fahrzeugs berechnet werden. Je nach Anwendung kann Lidar-Odometrie als Relativ-, aber auch als Absolutortung-Methode eingestuft werden. Eine der ersten Arbeiten in dem Thema der Relativortung war dabei die Methode GWD-ICP, die ein besonderes Augenmerk auf die Datenkomprimierung legte. Wobei konventionelle Methoden oft auf den Rohdaten eines Lidar-Scanners arbeiten, benutzt GWD-ICP eine komprimierte Beschreibung der Punktwolke mittels einer Gauß-Misch-Verteilung. Das ICP Verfahren, was normalerweise die euklidische Distanz zwischen Punktpaaren berechnet, konnte hierbei auf Paare von Gaußverteilungen angewendet werden. Das Resultat ist eine Assoziations und Optimierungsmethode, die rein auf Mengen von Gaußverteilungen arbeitet und somit den benötigten Speicher bei besonders dichten Punktwolken reduzieren kann. Die Methode wurde auf einer Fachkonferenz publiziert [12].

Eine weitere Arbeit wurde im Bereich der kartengestützten Lidar-Odometrie erarbeitet. Ein Hauptproblem bei Lidar- bzw. auch Inertial-Odometrie ist die Akkumulation von Fehlern über längere Distanzen. Die geschätzte Position weicht also über die gefahrene Strecke bzw. Zeit tendenziell mehr und mehr von der eigentlichen Position ab. Dieses Problem ist inherent in

Lidar Odometry, kann aber unter Dazunahme von zusätzlichen Informationen, wie z.B. GNSS Signalen, aber auch Karten, kompensiert werden. Die von uns entwickelte Methode benutzt dabei frei verfügbare Kartendaten von OpenStreetMap. Der essenzielle Vorteil dieser Daten ist im Vergleich zu hochaufgelösten Karten, dass sie sehr billig zu erzeugen sind und somit quasi überall zur Verfügung stehen. Wir konnten hier zeigen, dass selbst solche informationsarmen Karten bereits den Drift von Lidar Odometry in städtischen Gebieten eliminieren kann. Die Methode wurde auf einer Fachkonferez publiziert [13].

Neben den bereits veröffentlichten Arbeiten gibt es weitere, noch nicht vollständig abgeschlossene Arbeiten. Zum einen wurde von der Universität Göttingen in Zusammenarbeit mit iMAR Navigation GmbH ein Datensatz für Lidar-Inertial-Odometry (LIO) aufgenommen. Alle Daten sind bereits online verfügbar[1]. Eine Publikation steht in Kürze bevor. Auch eine weitere Veröffentlichung im Bereich der Lidar-Odometrie ist angestrebt. Hierbei wurde eine Methode entwickelt, die durch unabhängige ICP-Registrierungen eines Lidar-Scans gegen vorherige Keyframes einen dichten Pose-Graph erzeugt. Eine Optimierung dieses Graphen ermöglicht dann nicht nur das Schätzen der neusten Pose, sondern ebenfalls ein retrospektives Update von alten Posen.

Im folgenden findet sich eine detaillierte Beschreibung aller von der Universität Göttingen bearbeiteten Themen.

2 Eingehende Darstellung

2.1 Punktwolkenregistrierung mittels Gauß-Wassersteindistanzen für LiDAR-Odometrie

Modernere 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 [14] vorgeschlagen. *LiTAMIN* [15] und die Weiterentwicklung *LiTAMIN2* [16] sind neuere Methoden, die einen ähnlichen Ansatz verfolgen. Ein elementarer Unterschied zum an der UGOE verfolgten Ansatz ist

[1] https://odyssey.uni-goettingen.de/

dabei das eingesetzte Distanzmaß für die Ellipsen bzw. Gaußverteilungen.

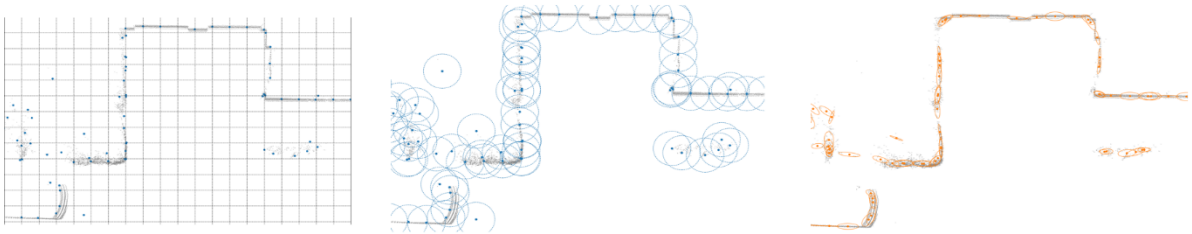

Abbildung 1: Schlüsselpunkte, Einzugsradien und entstehende Ellipsen in der vorgeschlagenen Verarbeitungspipeline

Die Verarbeitungspipeline des erarbeiteten Algorithmus *GWD-ICP* [12] ist ähnlich der Pipeline des punktbasierten *KISS-ICP*. Zunächst werden Schlüsselpunkte innerhalb einer gitterbasierten Voxelisierung identifiziert (Abb. 1, links). Zu jedem Schlüsselpunkt werden alle Punkte innerhalb eines definierten Einzugsradius (Abb. 1, 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. 1, rechts).

Abbildung 2: Schematisches Registrieren zwischen Karte (grau) und neuem Scan (orange).

Gaußverteilungen aus dem neuen Scan werden bestehenden Informationen in der internen Karte zugeordnet (Abb. 2, 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. 2, mittig). Basierend auf dieser Transformation können neue Verteilungen in die Karte eingefügt werden (Abb. 2, rechts), was das „Sichtfeld“ der Karte erweitert.

Beispielhafte Ergebnisse des Algorithmus sind in Abbildung 3 gezeigt. Die zugehörigen Daten sind Teil des öffentlichen Datensatzes *KITTI* [17], 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 [12]. Die Ergebnisse der bisherigen Forschung sprechen weder voll-

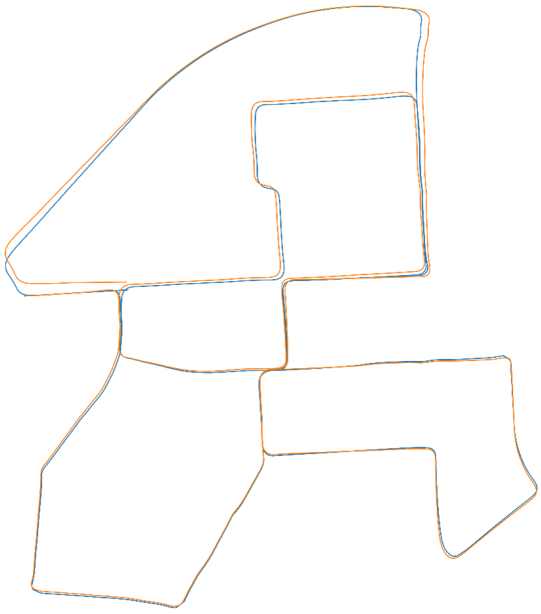

Abbildung 3: Beispielhafte Trajektorienschätzung des erarbeiteten Algorithmus (orange), gegen die tatsächliche Fahrtstrecke (blau).

umfänglich für den Einsatz von merkmalsbasierten Methodiken (wie GWD-ICP), noch für rein punktbasierte Ansätze. Weitere Arbeiten diesbezüglich werden angestrebt.

2.2 Integration von Straßennetzkarten

Außerdem wurde an der UGOE eine Methode zur Fusion von Straßennetzkarten mit Odometriedaten entwickelt. Grundsätzlich kann hierbei auf eine beliebige Odometrielösung, 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 Positierungsergebnisse 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 ei-

nes Monte Carlo Frameworks [18], oder diskrete Ankerpunkte, die evaluiert werden [19]. Rohe Laserdaten können durch entsprechende Vorverarbeitungsschritte in Straßen- und nicht-Straßenpunkte geteilt werden, was einen Abgleich mit dem Straßennetz ermöglicht [20]. 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 4 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. 5 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 4: Driftende LiDAR-Odometrie (orange) und genaue Schätzung durch Integration der Kartendaten (grün).

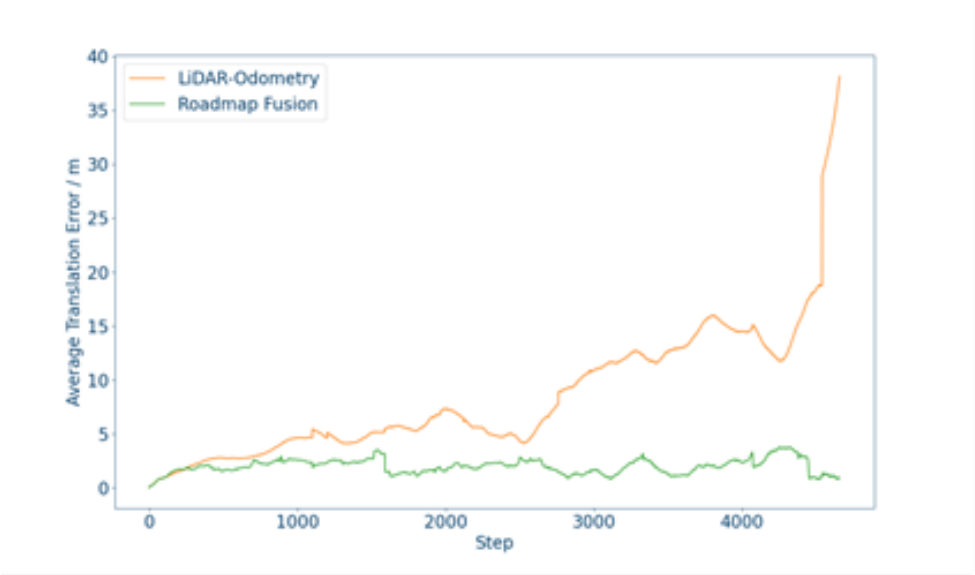

Abbildung 5: Fehler über Zeit von konventioneller LiDAR-Odometrie (orange) im Vergleich mit der von uns entwickelten Stützung mit Straßenwegenetze (grün).

2.3 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 [21] 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 [22], 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 [23, 24, 25], für das Ergebnisse auf allen öffentlichen Trajektorien des KITTI-Datensatzes erzielt werden können. Im Mittel konnte die Genauigkeit der Positionsschätzung auf dem Datensatz um über 40% verbessert werden. Auch auf Daten der Konsortialpartner konnten ähnliche Ergebnisse beobachtet werden. Abb. 6

zeigt die Genauigkeit der Ergebnisse und der registrierten Punktwolken (grün), visualisiert im Direktvergleich mit den Gebäudekarten (schwarz) und dem reinen SLAM-Verfahren (orange).

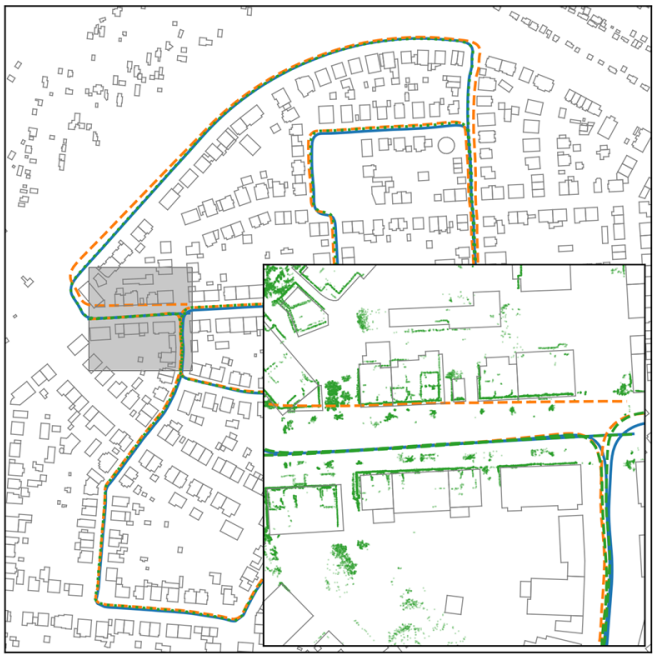

Abbildung 6: Visualisierung der geschätzten Trajektorie und der lokalen Karte (grün) auf dem KITTI [17] Datensatz. Der Drift der Lidar-Odometrie (orange) konnte mithilfe der Kartendaten von OpenStreetMap [26] (grau) verhindert werden.

2.4 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 Tunneln. 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 $\approx$ 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 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.

2.5 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 [27, 28] 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 [21] und MAD-ICP [29] oder LiDAR-Inertial-Odometrie-Methoden wie RKO-LIO [30] schneidet die entwickelte Methode auf dem MulRan [31] und unserem eigens aufgenommenen Datensatz *Odyssey* deutlich besser ab. Auf dem KITTI-Datensatz [17] liefert die Methode lediglich vergleichbare Ergebnisse. Eine Publikation der Methode ist angestrebt.

2.6 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.

2.7 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.

2.8 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 LiDARe 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 7: Präsentation des Projekts OKULAr bei der Nacht des Wissens in Göttingen.

2.9 Gegenüberstellung zu den vorgegebenen Zielen

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 [12] befasst sich mit der merkmalsbasierten Lokalisierung und dem Ziel, eine kompakte Kartenrepräsentation in Form eines Gauß-Mischmodells zu erzeugen. Die zweite Publikation [13] widmet sich der Integration von niedrig aufgelösten Kartendaten. Da nur eine begrenzte Menge an hochaufgelösten 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 2.3 beschriebenen Methode mit hochaufgelösten 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.

2.10 Wichtigste Positionen des zahlenmäßigen Nachweises

Die wichtigste Position des zahlenmäßigen Nachweises besteht aus Personalkosten.

2.11 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.

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

Im Rahmen des Projektes wurde die in Abschnitt 2.3 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 2.4 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 2.1 beschriebene Methode wurde auf der *Combined SDF and MFI Conference 2023* vorgestellt und veröffentlicht. Eine Veröffentlichung der in Abschnitt 2.5 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 2.2 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 [12] 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.

2.13 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 2.3 beschriebenen Methode wurde kurz nach der Veröffentlichung des Preprints der hier beschriebenen Methode veröffentlicht. Ein fundamentaler methodischer Unterschied besteht darin, dass [25] eine Pose-Graph-Optimierung verwendet, um zwei Schätzungen miteinander zu fusionieren, während die im Projekt OKULAr entwickelte Methode [13] die Fusion über einen Complementary-Filter realisiert. Unter [32] ist eine verwandte Arbeit zu der von uns beschriebenen Methode in Abschnitt 2.4 publiziert worden.

2.14 Erfolgte oder geplante Veröffentlichungen des Ergebnisses

Die beiden in 2.1 und 2.3 beschriebenen Methoden wurden auf Fachkonferenzen publiziert [13, 12]. Die Arbeiten an dem Odyssey-Datensatz (Abschnitt 2.4) wurden abgeschlossen. Sowohl Daten als auch ein Preprint sind online vefügbar [1]. Eine erste Version der in Abschnitt 2.5 beschriebenen Methode wurde bereits veröffentlicht [33]. 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 Abschlussvideo[2] zusammengefasst.

Literaturverzeichnis

[1] Franz Andert u. a. „OKULAr - Optische KI-basierte Umfeldwahrnehmung und Lokalisierung für automatisierte Fahrzeuge“. de. In: (Nov. 2025). DOI: 10.34657/26854.

[2] 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/TRO.2016.2624754.

[3] 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.

[4] 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.

[5] 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.

[6] 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.

[7] 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.

[8] 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.

[1] https://odyssey.uni-goettingen.de/
[2] https://youtu.be/ZiVMJZsKAmA

[9] Ioan Andrei Bârsan et al. *Learning to Localize Using a LiDAR Intensity Map*. 2020. arXiv: 2012.10902 [cs.CV]. URL: https://arxiv.org/abs/2012.10902.

[10] 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.

[11] 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.

[12] 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.

[13] 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.

[14] 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.

[15] 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.

[16] 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.

[17] Andreas Geiger et al. "Vision meets robotics: The kitti dataset". In: *The international journal of robotics research* 32.11 (2013), pp. 1231–1237.

[18] 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.

[19] 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.

[20] 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.

[21] 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.

[22] Walter T Higgins. “A comparison of complementary and Kalman filtering”. In: *IEEE Transactions on Aerospace and Electronic Systems* 3 (1975), pp. 321–325.

[23] Matteo Frosi, Veronica Gobbi, and Matteo Matteucci. “OSM-SLAM: Aiding slam with openstreetmaps priors”. In: *Frontiers in Robotics and AI* 10 (2023), p. 1064934.

[24] Augusto Luis Ballardini et al. “Vehicle localization using 3D building models and point cloud matching”. In: *Sensors* 21.16 (2021), p. 5356.

[25] 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.

[26] OpenStreetMap contributors. *Planet dump retrieved from https://planet.osm.org*. https://www.openstreetmap.org. 2017.

[27] 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.

[28] David Droeschel 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.

[29] 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.

[30] Meher V. R. Malladi et al. *A Robust Approach for LiDAR-Inertial Odometry Without Sensor-Specific Modeling*. 2025. arXiv: 2509.06593 [cs.RO]. URL: https://arxiv.org/abs/2509.06593.

[31] 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.

[32] Easton R. Potokar et al. *FORM: Fixed-Lag Odometry with Reparative Mapping utilizing Rotating LiDAR Sensors*. 2025. arXiv: 2510.09966 [cs.RO]. URL: https://arxiv.org/abs/2510.09966.

[33] 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]. URL: https://arxiv.org/abs/2503.21293.