

Ein Jahr auf ländlichen Straßen: Aufnahme eines multimodalen Datensatzes für das automatisierte Fahren

Franz Albers, Torsten Bertram

Lehrstuhl für Regelungssystemtechnik
Technische Universität Dortmund
Otto-Hahn-Straße 8, 44227 Dortmund
E-Mail: franz.albers@tu-dortmund.de

1 Einführung

In den vergangenen Jahren wurden vor allem durch die Entwicklung leistungsfähiger datengetriebener Methoden erhebliche Fortschritte im Bereich des automatisierten Fahrens erzielt. Ein zentraler Erfolgsfaktor ist die Verfügbarkeit von großen Datensätzen, die das Training und das Testen von datenbasierten Modellen in realistischen Szenarien ermöglichen. Aktuell verfügbare Datensätze fokussieren sich dabei überwiegend auf Autobahnen und urbane Gebiete mit einer gut ausgebauten Infrastruktur. Ländliche Regionen wurden bisher hingegen nur wenig berücksichtigt, obwohl sie einige besondere Herausforderungen aufweisen: Spärlich ausgebaute Infrastruktur, teilweise fehlende bzw. schlecht sichtbare Fahrbahnmarkierungen, ungeräumte Fahrbahnen bei Schnee, morgendlicher Nebel, Wildwechsel oder wechselnde Lichtverhältnisse bei Fahrten durch Waldgebiete stellen unter anderem aufgrund der Domain-Gaps zu bestehenden Datensätzen mit definierten Operational Design Domains (ODD) besondere Herausforderungen an die Sensoren und Modelle.

Daten aus der ländlichen Domäne sind für die Entwicklung und Evaluierung von domänenübergreifenden lernbasierten Algorithmen von großer Bedeutung. Sun et al. konstatieren bei der Evaluierung von Objektdetektionsalgorithmen

auf dem Waymo Open Dataset [1] einen deutlichen Leistungsabfall, falls die Modelle auf einem Datensatz aus einer städtischen bzw. einer vorstädtischen Region trainiert werden und auf dem jeweils anderen Datensatz validiert werden [1]. Lang et al untersuchen dabei die 3D Detektionen von Fußgängern und Fahrzeugen mit dem lidar-basierten Pointpillars Modell [2]. Diese Erkenntnis unterstreicht die Bedeutung domänenübergreifender Datensätze und insbesondere den Bedarf an aufgezeichneten Fahrten im ländlichen Raum.

Der vorliegende Beitrag stellt die Vorgehensweise und Herausforderungen bei der Aufnahme des neuen DEMANDAR Datensatzes, den Aufbau des verwendeten Messfahrzeugs (siehe Bild 1), beispielhafte Daten sowie die Maßnahmen zur Annotierung der Daten vor. Um verschiedenste Witterungsverhältnisse abzubilden, werden über einen Zeitraum von einem kompletten Jahr Daten auf einer definierten Messstrecke in der Region Südwestfalen erhoben. Der Datensatz bildet somit die gleiche Strecke zu verschiedenen Tages- und Jahreszeiten bei unterschiedlichen Witterungsverhältnissen ab.

Nach bestem Wissen der Autoren ist bisher kein multimodaler und multisaisonaler Datensatz öffentlich verfügbar, der umfangreiche Fahrten aus ländlichen Regionen enthält. Des Weiteren wurden bisher nur wenige Datensätze publiziert, die neben Lidar- und Kameradaten auch Daten von Automotive-Radarsensoren enthalten. Ein weiteres Alleinstellungsmerkmal des Datensatzes ist die zentimetergenaue Referenzlokalisierung durch ein kinematisches Echtzeit-Inertial-Navigationssystem (RTK-DGNSS/INS).

2 Stand der Technik

Es gibt bereits einige Datensätze für verschiedene Aufgaben im Bereich des automatisierten Fahren, wie zum Beispiel die Objektdetektion oder Lokalisierung. Oftmals umfassen Datensätze eigene Benchmarks zum Vergleich verschiedener Ansätze. In diesem Abschnitt werden einige in der Forschung zum automatisierten Fahren häufig genutzte Datensätze vorgestellt.

Der KITTI-Datensatz [3] war einer der ersten öffentlich verfügbaren Datensätze. Es werden Lidar-, Kamera- und RTK-GPS/IMU-Daten synchronisiert

bereitgestellt. Der Datensatz enthält allerdings keine Radardaten. Der KITTI-Datensatz enthält verschiedene Szenarien, die auf zumeist städtischen Straßen in Karlsruhe aufgenommen wurden. Im Laufe der Zeit wurde der KITTI-Datensatz mit umfassenden Annotationen und Benchmarks für verschiedene Anwendungen erweitert (z.B. Straßenerkennung [4] oder semantische Punktwolkenannotationen [5]).

Das Waymo Open Dataset [1] wurde mit einer Flotte selbstfahrender Fahrzeuge aufgezeichnet, die jeweils mit mehreren Lidarsensoren, Kameras und einem RTK-GPS/IMU-System ausgestattet waren. Radarsensoren wurden ebenfalls nicht zur Umfelderkennung verwendet. Der Datensatz wurde in verschiedenen städtischen und vorstädtischen Regionen in San Francisco, Phoenix und Mountain View, USA sowohl bei Tag als auch bei Nacht aufgezeichnet. Damit ist der Waymo-Datensatz einer der umfangreichsten, öffentlich verfügbaren Datensätze für das automatisierte Fahren.

Der nuScenes-Datensatz [6] stellt als einer der ersten großen Datensätze für automatisiertes Fahren neben Lidar-, Kamera- und GNSS/IMU-Daten auch die Daten von Automotive-Radarsensoren bereit. nuScenes liefert hochauflösende Daten für über 1.000 Szenarien. Unterschiedliche Wetter- und Lichtbedingungen sind ebenfalls enthalten. Der Datensatz deckt ca. 1.000 km von hauptsächlich städtischen Straßennetzen in Boston und Singapur ab. Der nuScenes-Datensatz wurde später um punktuelle semantische Lidar-Annotationen und einen panoptischen Benchmark erweitert [7].

Im Oxford RobotCar-Datensatz [8] sind Lidar- sowie GPS/IMU-Daten und Stereokamerabilder enthalten. Die Sensorik wurde später um einen rotierenden 360°-NavTech-Radar ergänzt [10]. Die RobotCar-Datensätze wurden durch wiederholte Fahrten auf der gleichen städtischen Route in Oxford, Großbritannien aufgezeichnet. Zu unterschiedlichen Tageszeiten wurden die Messfahrten für den ursprünglichen Datensatz über ein Jahr und für die Radarerweiterung über einen Monat durchgeführt. Nach bestem Wissen der Autoren sind der nuScenes- und der Oxford Radar RobotCar-Datensatz die bisher einzigen veröffentlichten Datensätze, die das komplette 360°-Sichtfeld um das Fahrzeug mit Lidar-, Radar- und Kameramodalitäten abdecken.

Der Boreas-Datensatz [9] wurde ebenfalls durch das wiederholte Befahren einer städtischen Route über ein ganzes Jahr hinweg in Toronto, Kanada aufgezeichnet. Der Datensatz umfasst verschiedene herausfordernde Wetter- und Lichtbedingungen (z. B. Regen, Schnee, Nacht usw.). Die Aufnahmeplattform verfügt über einen rotierenden 360°-Lidar auf dem Dach, eine nach vorne gerichtete Kamera und einen GNSS/IMU-Sensor, der eine Lokalisierungsgenauigkeit von bis zu 2-4 cm erreicht. Ähnlich wie beim Oxford Radar RobotCar-Datensatz [10] wird auch hier ein rotierender 360° NavTech Radar verwendet. Die Doppler-Messungen des Radars sind als relevante Zustandsgröße jedoch nicht enthalten. Somit wird in beiden Datensätzen einer der wesentlichen Vorteile von Radar-Sensoren gegenüber Lidar-Sensoren nicht genutzt [11].

Der View-of-Delft-Datensatz [12] umfasst Daten von einem rotierenden 360°-Lidar, einer Stereokamera und einem RTK-GPS/IMU Navigationssystem. Zusätzlich wurde ein nach vorne gerichteter 3+1D Automotive Radarsensor verwendet. Neben Entfernung-, Azimuth- und Doppler-Messungen liefert dieser Sensor auch eine Messung in der Elevation. Die Daten wurden auf den städtischen Straßen von Delft in den Niederlanden aufgezeichnet.

Tabelle 1 zeigt einen kurzen Überblick über die erwähnten Datensätze.

Tabelle 1: Überblick der Datensätze im Bereich des automatisierten Fahrens

| Datensatz | Kamera | Lidar | Radar | GNSS | Ort |
|---------------------|--------|-------|-------|------|------------------------|
| KITTI [3] | ✓ | ✓ | ✗ | ✓ | Karlsruhe |
| Waymo [1] | ✓ | ✓ | ✗ | ✓ | Phoenix, San Francisco |
| nuScenes [6] | ✓ | ✓ | ✓ | ✓ | Boston, Singapur |
| Radar RobotCar [10] | ✓ | ✓ | ✓ | ✓ | Oxford |
| Boreas [9] | ✓ | ✓ | ✓ | ✓ | Toronto |
| View-of-Delft [12] | ✓ | ✓ | ✓ | ✓ | Delft |
| Demandar | ✓ | ✓ | ✓ | ✓ | Südwestfalen |

3 Messfahrzeug

Als Messfahrzeug diente ein Nissan Leaf ZE0 mit einer umfangreichen Sensorik (siehe Bild 1). Die folgenden Abschnitten beschreiben den technischen

Aufbau sowie die verwendeten Koordinatensysteme und die Vorgehensweise bei der Kalibrierung der Sensoren.



Bild 1: TU Dortmund Forschungsfahrzeug

3.1 Technischer Aufbau des Messfahrzeugs

Das Messfahrzeug verfügt über einen Mid-Range- (Ouster OS1), einen Long-Range-Lidar (Ouster OS2) und sechs RGB-Kameras (FLIR Chameleon 3), die auf einem Dachgepäckträger montiert sind. Hinter der Windschutzscheibe befindet sich eine Serien-Frontkamera von Mobileye. An den Ecken des Fahrzeugs sind vier prototypische 77 GHz Mid-Range Automotive Radar-Sensoren hinter den Stoßfängern verbaut. Ein RTK-DGNSS/INS (GeneSys ADMA-G Eco+) ermöglicht eine zentimetergenaue Referenzlokalisierung.

Bild 2 zeigt einen Überblick über den technischen Aufbau des Versuchsfahrzeugs. Die Daten der verschiedenen Sensoren werden auf einem Zentralrechner mit AMD Ryzen 7 7700X Prozessor, 64 GB RAM, 8 TB SSD Speicher, einer Nvidia GTX 1050 Ti GPU und einem 24 V Netzteil zusammengeführt. Der Rechner verfügt über zwei PCI CAN FD Interface Karten von PEAK Systems, über die mithilfe der SocketCAN Treiber mit verschiedenen CAN Geräten kommuniziert werden kann. Über diese Schnittstelle werden unter anderem

die Daten vom fahrzeugeigenen CAN-Bus empfangen, dekodiert und geloggt. Einige Signale vom Fahrzeug-CAN-Bus, wie beispielsweise die Fahrzeugschwindigkeit, dienen wiederum als Eingangssignale für die Radarsensoren und für die Mobileye Frontkamera. Die weiteren sechs Kameras sind über USB 3.1 mit dem Zentralrechner verbunden.

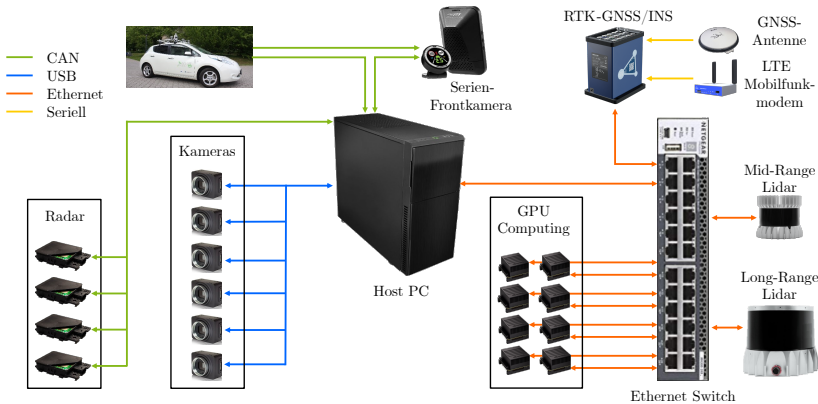


Bild 2: Technischer Aufbau des Messfahrzeugs

Die beiden Lidar-Sensoren und das RTK-DGNSS/INS sind über einen 10 Gigabit Ethernet Switch mit dem Zentralrechner verbunden. Neben den Sensoren sind zudem acht Nvidia Jetson AGX Xavier Developer Kits für besonders rechenintensive Anwendungen im Kofferraum des Forschungsfahrzeugs verbaut.

Beide Lidare verfügen über eine Auflösung von 1.024×64 Punkten bei 20 Hz. Der Ouster OS2 Long-Range Lidar hat eine Reichweite von bis zu 210 m bei einem Sichtfeld von $360^\circ \times 22.5^\circ$. Pro Sekunde werden somit 1.310.720 Punkte gemessen. Der Ouster OS1 Mid-Range Lidar hat hingegen eine etwas geringere Reichweite von bis zu 170 m bei einem etwas größeren Öffnungswinkel von $360^\circ \times 45^\circ$. Der Mid-Range Lidar verfügt zudem über eine Dual Return Funktionalität, bei dem nicht nur der erste, sondern auch der zweite Reflex eines Laserpulses gemessen wird. Dadurch können auch Objekte erfasst werden, die sich hinter anderen Objekten (z.B. Glasscheiben oder Nebel) befinden. Der Mid-Range Lidar kann somit 2.621.440 Messpunkte pro Sekunde erfassen.

Neben einer Punktwolke liefert der Mid-Range Lidar zudem eine Intensitätsmessung, welche die Reflektivität der Objekte erfasst. Beide Lidare verfügen zudem über eine integrierte IMU mit 6 Freiheitsgraden.

Bei den Radarsensoren handelt es sich um prototypische Frequency Modulated Continuous Wave (FMCW) Automotive Sensoren. Die Sensoren verwenden ein Frequenzspektrum im 77 GHz Band und besitzen ebenfalls eine Aufnahme rate von 20 Hz. Aufgezeichnet werden sowohl die von den Sensoren detektierten Objekte als auch die Radar-Targets.

Die FLIR Chameleon3 RGB Kameras verwenden einen Global Shutter, um unerwünschte Bildartefakte bei bewegten Objekten zu vermeiden. Die Auflösung der Kameras beträgt 2.048×1.152 Pixel (ca. 3,2 Megapixel) bei 20 Hz. Um die Datenrate möglichst gering zu halten, werden Kamerabilder nicht als Rohbilder sondern als komprimierte Einzelbilder aufgezeichnet. Die Mobileye Frontkamera verfügt über eine integrierte Objekterkennung sowie -klassifizierung und liefert statt einem Kamerabild direkt eine Objektliste mit detektierten Hindernissen und Verkehrszeichen.

Das RTK-DGNSS/INS besteht aus einer GNSS Antenne auf dem Dach des Fahrzeugs, einem LTE Mobilfunkmodem, über das NTRIP Korrekturdaten von Bodenstationen empfangen werden können, und der Automotive Dynamic Motion Analyzer (ADMA) Einheit, die in einer IMU mit 9 Freiheitsgraden hochgenaue Beschleunigungssensoren und Gyroskope (Faserkreisel) enthält. Die Genauigkeit der Positionsbestimmung liegt bei 0,01 m, die Genauigkeit des erfassten Roll- und Nick-Winkels liegt bei $0,01^\circ$ und des Gier-Winkels bei $0,025^\circ$. Im Falle einer Verschlechterung oder eines Ausfalls des GNSS Empfangs, beispielsweise in Tunneln oder in bewaldeten Gebieten, wird die Position durch diese Sensoren für einen gewissen Zeitraum sehr genau geschätzt und bereitgestellt.

Alle umfelderfassenden Sensormodalitäten (Lidar, Radar und Kamera) decken die komplette 360° Rundumsicht ab. Durch die vergleichsweise hohen Aufnahme raten und die Vielzahl von Sensoren ergibt sich eine entsprechend hohe Datenrate von insgesamt ca. 350 MB/Sekunde. Die Aufnahme einer einminütigen Fahrt erzeugt somit bereits eine Datenmenge von 20 GB.

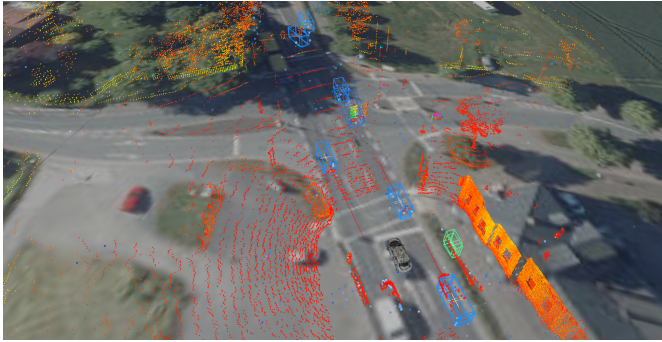


Bild 3: Beispielhafte Darstellung der Sensordaten.

Beispielhaft dargestellt sind die Sensordaten in Bild 3. Die Lidar-Punktwolke ist rötlich dargestellt. Die Radar-Targets sind als bläuliche Punktwolken abgebildet. Die dargestellten Bounding Boxen veranschaulichen die durch die Radarsensoren detektierten Objekte, die dazugehörigen Geschwindigkeitsvektoren (rote Linie an der Spitze der Bounding Boxen) und die Klassifizierung der Objekte (z.B. entsprechen blaue Bounding Boxen Fahrzeugen, grüne Boxen Fahrrädern). Das statische Orthofoto im Hintergrund zeigt die zentimetergenaue Lokalisierung des Ego-Fahrzeugs auf der unteren Linksabbiegerspur.

Als grundlegendes Framework wird im Forschungsfahrzeug das Robot Operating System 2 (ROS 2) [13] verwendet. ROS 2 ist ein Open-Source Publisher/Subscriber Framework, das ursprünglich aus der Robotik stammt. Unter anderem auch aufgrund seiner Modularität wird ROS 2 inzwischen in vielen Forschungsfahrzeugen eingesetzt. Ein großer Vorteil ist zudem die weite Verbreitung von ROS 2, wodurch auf eine Vielzahl von bereits verfügbaren ROS 2 Paketen zur Datenverarbeitung zurückgegriffen werden kann. Basierend auf ROS 2 wurde Autoware [14] entwickelt. Autoware ist ein Open-Source Software Stack für das automatisierte Fahren. Teile von Autoware, wie beispielsweise die Komponenten Sensing, Perception und Localization, werden im hier vorgestellten Forschungsfahrzeug verwendet.

Die Spannungsversorgung der Messtechnik ist komplett vom Bordnetz getrennt und erfolgt über zwei 12 Volt Batterien mit 120 Ah.

3.2 Koordinatensysteme

Dieser Abschnitt beschreibt die Koordinatensysteme des Messfahrzeugs. Alle Koordinatensysteme sind rechtshändig. Für jeden Sensor ist mindestens ein eigenes Sensorkoordinatensystem definiert. Zudem existieren mehrere fahrzeug-feste Koordinatensysteme, bei denen die x -Richtung jeweils in Fahrtrichtung nach vorne zeigt: *base_link* (Mitte der Hinterachse auf den Boden projiziert), *front_axle_center_link* (Mitte der Vorderachse), *rear_axle_center_link* (Mitte der Hinterachse) sowie *front_bumper* (Vorderster mittiger Punkt des Fahrzeugs auf den Boden projiziert).

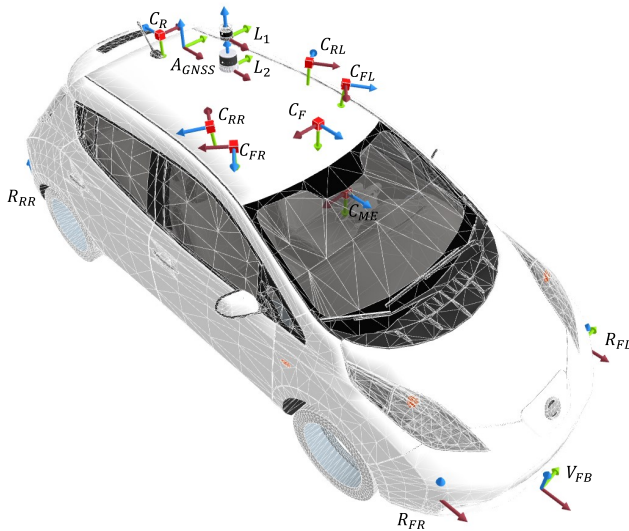


Bild 4: Koordinatensysteme des Messfahrzeugs. Die x -Richtung ist jeweils rot, die y -Richtung grün und die z -Richtung blau dargestellt.

Bild 4 zeigt die verschiedenen Sensorkoordinatensysteme des Messfahrzeugs. Von den fahrzeugeigenen Koordinatensystemen ist in der Abbildung lediglich das *front_bumper* Koordinatensystem (V_{FB}) dargestellt, da die anderen Koordinatensysteme innerhalb des Fahrzeugs liegen.

Die Koordinatensysteme der beiden Lidar-Sensoren werden in der Abbildung durch die Lidar-Modelle markiert. Die beiden Koordinatensysteme *lidar_os1_*

base_link (in Bild 4: L_1) und *lidar_os2_base_link* (L_2) liegen gemäß dem Sensoraufbau in der Mitte des Fahrzeugdachs übereinander. Für beide Lidare sind weitere Sub-Koordinatensysteme für die jeweilige IMU sowie für den Laser definiert.

Die Einbaupositionen der Kameras sind in Bild 4 durch die roten Boxen und die Koordinatensysteme C markiert. Dargestellt sind jeweils die Bildkoordinatensysteme (x -Achse zeigt nach rechts, y -Achse nach unten, z -Achse ins Bild). Die Mobileye Frontkamera C_{ME} ist hinter der Windschutzscheibe verbaut.

Die Koordinatensysteme R der Radarsensoren liegen an den vier Ecken des Fahrzeugs. Die x -Achse zeigt dabei nicht in die Einbaurichtung, die jeweils $\pm 45^\circ$ zur Fahrtrichtung rotiert ist, sondern ist entsprechend der fahrzeugeigenen Koordinatensysteme in Fahrtrichtung nach vorne ausgerichtet. Die Berücksichtigung der Einbauwinkel erfolgt intern in den Radarsensoren.

Zwischen den Koordinatensystemen der Lidare und der Rückkamera liegt ein weiteres Koordinatensystem A_{GNSS} für die GNSS-Antenne. Das Koordinatensystem des RTK-DGNSS/INS ist nicht im Bild verzeichnet, da der ADMA im Kofferraum des Fahrzeugs installiert ist und es somit ebenfalls dort liegt.

3.3 Kalibrierung

Die intrinsische Kalibrierung der Kameras erfolgte mit dem ROS 2 Paket *intrinsic_camera_calibrator* aus dem Tier4 CalibrationTools Repository¹, das intern die Funktionalitäten der OpenCV Bibliothek [15] zur Kalibrierung [16] verwendet. Als Kalibrierungsmuster wurde ein Schachbrettmuster mit bekannten Abmessungen verwendet.

Die extrinsische Kalibrierung zwischen den einzelnen Kameras und einem Lidar wurde mit den Paketen *extrinsic_interactive_calibrator* und *extrinsic_tag_based_calibrator* aus demselben Repository durchgeführt. Die genaue Position des Lidars relativ zum *base_link* Koordinatensystem des Fahrzeugs sowie die Position der GNSS-Antenne relativ zum RTK-DGNSS/INS relativ bzw.

¹ Tier4 CalibrationTools GitHub Repository
<https://github.com/tier4/CalibrationTools>

zum *base_link* Koordinatensystem wurden manuell vermessen. Die Transformationen zwischen den verschiedenen fahrzeugfesten Koordinatensystemen (Mitte der Vorderachse, Mitte der Hinterachse, Mitte des vorderen Stoßfängers, *base_link*) wurden aus technischen Datenblättern bzw. einem CAD-Modell des Nissan Leaf ZE0 abgeleitet.

Die intrinsische und extrinsische Kalibrierung der vier Radarsensoren in Bezug auf die Mitte der Vorderachse des Fahrzeugs und die Kalibrierung der Mobileye Frontkamera in Bezug auf den auf den Boden projizierten vordersten Punkt des Fahrzeugs (*front_bumper*) wurden von dem jeweiligen Hersteller bzw. Lieferanten durchgeführt.

4 Datensatz

Seit August 2022 fährt das Messfahrzeug ca. einmal wöchentlich eine definierte Messstrecke in der Region Südwestfalen zur Datenaufnahme ab. Die Daten werden aktuell aufbereitet und annotiert. Geplant ist die Veröffentlichung des Datensatzes im Laufe des Jahres 2024. In den folgenden Abschnitten werden die Messstrecke und die für den Datensatz geplanten Annotierungen vorgestellt.

4.1 Messstrecke

Die Messstrecke umfasst mit Wohn-, Industrie- und Waldgebieten sowie Feldwegen und Bundesstraßen verschiedene für den ländlichen Raum charakteristische Abschnitte. Bei der Auswahl der Messstrecke wurde darauf geachtet, dass die Strecke eine Vielzahl unterschiedlicher Szenarien abbildet. Ein weiteres wichtiges Kriterium für die Messstrecke war ein durchgehend guter Mobilfunkempfang entlang der Route, um die NTRIP Korrekturdaten für das RTK-DGNSS/INS zu empfangen.

Die Länge der Messstrecke beträgt insgesamt ca. 23 km. Bei üblichem Verkehrsaufkommen liegt die Fahrzeit bei ca. 35 Minuten. Lokalisiert ist die Messstrecke zwischen den Mendener Ortsteilen Böserpe und Halingen sowie dem

Iserlohner Ortsteil Sümmern. Bild 5 zeigt den Verlauf der Messstrecke anhand einer RTK-DGNSS/INS Messung. Im dargestellten Streckenverlauf farblich kodiert ist die vom RTK-DGNSS/INS geschätzte Standardabweichung der Position in Metern. Kleinere Abweichungen kommen vor allem durch die eingeschränkte Sicht zum Himmel im Bereich eines Waldes vor. Auf den übrigen Streckenabschnitten liegt die Standardabweichung der Lokalisierung im Bereich weniger Zentimeter.

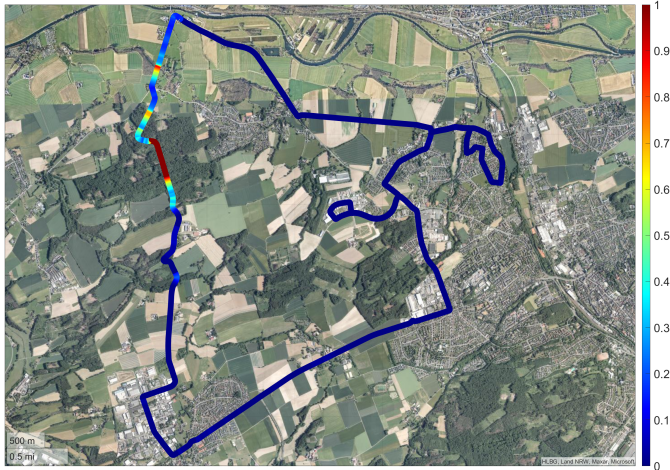


Bild 5: Route der Messstrecke. Die Farbskala gibt die Standardabweichung der vom RTK-DGNSS/INS bestimmten Position in Metern an.

4.2 Annotierungen

Der eigentliche Wert von Datensätzen für das automatisierte Fahren beruht auf der Verfügbarkeit von annotierten Ground-Truth-Daten. Für den Datensatz geplant sind Referenzdaten für die Ego-Lokalisierung, Objekte und Wetterdaten. Die meist zentimetergenaue Referenzlokalisierung wird dabei inklusive Standardabweichung direkt durch das RTK-DGNSS/INS aufgezeichnet.

Die Objektannotationen erfolgen mithilfe eines Offline-Auto-Labeling-Tools auf Basis der Lidar-Punktwolke mit anschließender manueller Validierung. Die Offline-Annotation besitzt den Vorteil, dass zukünftige Sensordaten bekannt

sind und in die Entscheidungsfindungen mit einbezogen werden. Durch mehrfaches alternierendes zeitliches Forward- und Backward-Tracking können somit auch Objekte verlässlich annotiert werden, die in einigen Zeitschritten nur wenige oder keine Messpunkte aufweisen. Neben der Detektionsgüte können auch die Abmessungen der Bounding Boxen von detektierten Objekten auf diese Weise verbessert werden. In Bild 6 werden beispielhaft die Ergebnisse der automatisierten Annotierung dargestellt. Das Ego-Fahrzeug ist blau dargestellt, andere Fahrzeuge sind grün, Fußgänger sind gelb und unbekannte statische Objekte sind orange.

Im Bild erkennbar sind auch teilweise Fehlklassifikationen und zu kleine Bounding Boxen für Fahrzeuge. Zum Zeitpunkt der Beitragsverfassung wird noch eine Version des Auto-Labeling-Tools verwendet, die für das Einsatzgebiet Autobahn entwickelt wurde. In Kürze wird eine neue Version des Tools verfügbar sein, die universeller einsetzbar ist und somit auch im ländlichen Raum bessere Ergebnisse liefert. Kleinere Fehler werden durch eine manuelle Validierung der Annotierungen korrigiert.

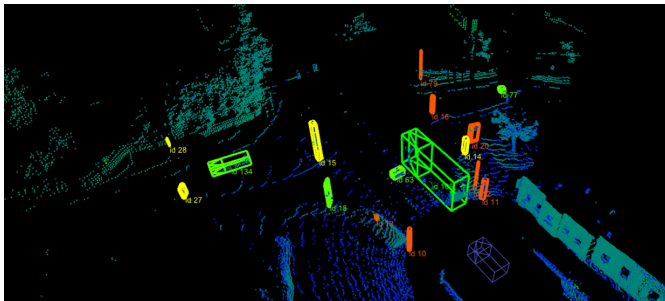


Bild 6: Ergebnisse der automatisierten Annotierung.

Die Wetterdaten werden über öffentlich verfügbare Wetterdatenbanken² bezogen.

² z.B. <https://www.timeanddate.de/wetter/deutschland/menden/rueckblick>

4.3 Aktueller Stand der Datenaufnahme

Seit August 2022 wurde die Messstrecke befahren. Auf diese Weise wurden bisher über 1.100 km an Daten auf der Messstrecke in ca. 30 Stunden aufgenommen. Auf der Messstrecke wurde bisher eine Datenmenge von insgesamt über 20 TB aufgezeichnet.

Neben den Aufnahmen der Messstrecke wurden auch die Hin- und Rückfahrten von bzw. zur TU Dortmund aufgezeichnet (städtische Umgebung, Autobahn und ländliche Umgebung), wodurch pro Fahrt weitere 70 km an Daten aufgenommen wurden. Die gesamte aufgezeichnete Datenmenge liegt somit bei über 60 TB bei einer Gesamtstrecke von über 4.500 km.

Im Laufe der Messfahrten veränderte sich die Sensorkonfiguration leicht. Die vier Radarsensoren wurden im Herbst 2022 installiert. Die vier Seitenkameras wurden erst zu Beginn des Jahres 2023 in Betrieb genommen. Zudem fiel einer der beiden Lidare für mehrere Monate aufgrund eines Wasserschadens bei einer Regenfahrt aus und wurde erst kürzlich durch ein neueres Modell ersetzt. Dementsprechend liegen die Datenraten bei den letzten Messfahrten deutlich höher als bei den ersten Messfahrten. Unter anderem aufgrund dieser Umstände werden die Messfahrten noch bis Ende März 2024 fortgeführt, um ein komplettes Jahr mit der gleichen Sensorkonfiguration abzudecken.

5 Zusammenfassung und Ausblick

In diesem Beitrag wurde das Forschungsfahrzeug der TU Dortmund sowie die Vorgehensweise bei der Aufnahme und Aufbereitung eines neuen multimodalen und multisaisonalen Datensatzes aus dem ländlichen Raum und die dafür verwendete Messstrecke vorgestellt. Der Datensatz umfasst Lidar-, Kamera- und (Automotive-)Radardaten sowie eine hochgenaue Referenzlokalisierung durch ein RTK-DGNSS/INS.

Aufgrund der langfristigen Datenaufnahme stehen für die jeweiligen Streckenabschnitte jeweils eine Vielzahl verschiedener Aufnahmen zu wechselnden

Tages- und Jahreszeiten bei unterschiedlichen Wetterbedingungen zur Verfügung. Auf diese Weise kann der Einfluss der Witterungsverhältnisse auf die Messungen unterschiedlicher Sensoren und auf Algorithmen der Umfelderkennung und Ego-Lokalisierung systematisch untersucht werden.

Der Datensatz wird aktuell für die Veröffentlichung aufbereitet und im Laufe des Jahres 2024 veröffentlicht.

Danksagung

Dieser Beitrag entstand im Zuge des Forschungsprojekts „DEmandäR“, das im Rahmen der Förderrichtlinie „Förderung der Vernetzten Mobilität und des Mobilitätsmanagements“ durch das Ministerium für Umwelt, Naturschutz und Verkehr des Landes Nordrhein-Westfalen und die Bezirksregierung Arnsberg gefördert wurde.

Literatur

- [1] P. Sun, H. Kretzschmar, X. Dotiwalla, A. Chouard, V. Patnaik, P. Tsui, J. Guo, Y. Zhou, Y. Chai, B. Caine, V. Vasudevan, W. Han, J. Ngiam, H. Zhao, A. Timofeev, S. Ettinger, M. Krivokon, A. Gao, A. Joshi, Y. Zhang, J. Shlens, Z. Chen und D. Anguelov. „Scalability in Perception for Autonomous Driving: Waymo Open Dataset“. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2020.
- [2] A. H. Lang, S. Vora, H. Caesar, L. Zhou, J. Yang und O. Beijbom. „Pointpillars: Fast encoders for object detection from point clouds“. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2019.
- [3] A. Geiger, P. Lenz, C. Stiller und R. Urtasun. „Vision meets robotics: The KITTI dataset“. In: *The International Journal of Robotics Research*, 32.11, S. 1231–1237, 2013.

- [4] J. Fritsch, T. Kuhn und A. Geiger. „A new performance measure and evaluation benchmark for road detection algorithms“. In: *16th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, 2013.
- [5] J. Behley, M. Garbade, A. Milioto, J. Quenzel, S. Behnke, J. Gall und C. Stachniss. „Towards 3D LiDAR-based semantic scene understanding of 3D point cloud sequences: The SemanticKITTI Dataset“. In: *The International Journal on Robotics Research*, 40.8-9, S. 959–967, 2021.
- [6] H. Caesar, V. Bankiti, A. H. Lang, S. Vora, V. E. Liong, Q. Xu, A. Krishnan, Y. Pan, G. Baldan und O. Beijbom. „nuScenes: A Multimodal Dataset for Autonomous Driving“. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, S. 11618–11628. 2020.
- [7] W. K. Fong, R. Mohan, J. V. Hurtado, L. Zhou, H. Caesar, O. Beijbom und A. Valada. „Panoptic Nuscenes: A Large-Scale Benchmark for LiDAR Panoptic Segmentation and Tracking“. In: *IEEE Robotics and Automation Letters*, 7.2, S. 3795–3802, 2022.
- [8] W. Maddern, G. Pascoe, C. Linegar und P. Newman. „1 year, 1000 km: The Oxford RobotCar dataset“. In: *The International Journal of Robotics Research*, 36.1, S. 3–15, 2017.
- [9] K. Burnett, D. Yoon, Y. Wu, A. Li, H. Zhang, S. Lu, J. Qian, W.-K. Tseng, A. Lambert, K. Leung, A. Schoellig, T. Barfoot. „Boreas: A multi-season autonomous driving dataset“. In: *The International Journal of Robotics Research*, 42.1-2, S. 33–42, 2023.
- [10] D. Barnes, M. Gadd, P. Murcutt, P. Newman und I. Posner. „The Oxford Radar RobotCar Dataset: A Radar Extension to the Oxford RobotCar Dataset“. In: *IEEE International Conference on Robotics and Automation (ICRA)*, S. 6433–6438, 2020.
- [11] O. Schumann, M. Hahn, N. Scheiner, F. Weishaupt, J. F. Tilly, J. Dickmann und C. Wöhler. „RadarScenes: A Real-World Radar Point Cloud Data Set for Automotive Applications“. In: *Proceedings of 24th*

International Conference on Information Fusion (FUSION), S. 1-8, 2021.

- [12] A. Palffy, E. Pool, S. Baratam, J. Kooij und D. Gavrilu. „Multi-class Road User Detection with 3+1D Radar in the View-of-Delft Dataset“. In: *IEEE Robotics and Automation Letters*, 7.2, S. 1, 2022.
- [13] S. Macenski, T. Foote, B. Gerkey, C. Lalancette und W. Woodall. „Robot Operating System 2: Design, architecture, and uses in the wild“. In: *Science Robotics*, 7.66, 2022.
- [14] S. Kato, S. Tokunaga, Y. Maruyama, S. Maeda, M. Hirabayashi, Y. Kitsukawa, A. Monrroy, T. Ando, Y. Fujii und T. Azum. „Autoware on Board: Enabling Autonomous Vehicles with Embedded Systems“. In: *9th ACM/IEEE International Conference on Cyber-Physical Systems*, S. 287–296, 2018.
- [15] G. Bradski und A. Kaehler. „Learning OpenCV: Computer vision with the OpenCV library“. *O'Reilly Media, Inc.*, 2008.
- [16] Z. Zhang. „A flexible new technique for camera calibration“. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22.11, S.1330–1334, 2000.
- [17] J.-K. Huang, S. Wang, M. Ghaffari und J. W. Grizzle. „LiDARTag: A Real-Time Fiducial Tag System for Point Clouds“. In: *IEEE Robotics and Automation Letters*, 6.3, S. 4875–4882, 2021.