

Evaluation eines mobilen Messsystems zur automatisierten Erkennung und Höhenbestimmung von Bordsteinen

Evaluation of a Mobile Mapping System for Automatic Curb Detection and Height Measurement

Simon Pfeil, Thomas Wiemann, Marcel Storch

Dieser Beitrag präsentiert einen Ansatz zur Detektion von Bordsteinen und zur Abschätzung ihrer Höhe in 3D-LiDAR-Punktwolken mittels eines Ouster-OS1-128-Sensors. Die entwickelte Methodik kombiniert effektiv verschiedene Techniken im 3D- und 2D-Raum und ist in der Lage, auch verrauschte Daten zu prozessieren. Dabei wird die Punktwolke in einem 2D-Raster organisiert, bevor die Bodenpunkte durch RANSAC bestimmt werden. Anschließend wird mittels Region Growing eine Straßensegmentierung durchgeführt. Mit dem Canny-Edge-Algorithmus werden die Kanten der Straße extrahiert, um sie auf Bordsteine zu untersuchen. In der Evaluation wird gezeigt, dass diese Methodik auf einer Strecke von 3 000 Metern 92 % der vorhandenen Bordsteine identifiziert, insgesamt wurden 96 % der Bordsteinpunkte korrekt klassifiziert. Darüber hinaus zeigt der Ansatz vielversprechende Ergebnisse bei der Höhenschätzung und konnte die Bordsteinkategorien 3–7 cm und größer als 7 cm effektiv klassifizieren.

Schlüsselwörter: Bordsteindetektion, Mobile Mapping, 3D-Laserscanning

This article presents an approach for detecting curbs and estimating their height in 3D LiDAR point clouds using an Ouster OS1-128 sensor. The developed methodology effectively combines various techniques in 3D and 2D space and is capable of processing noisy data. The point cloud is organized into a 2D grid before ground points are determined using RANSAC. Subsequently, street segmentation is performed using region growing. The Canny edge algorithm is employed to extract the road edges to examine them for curbs. The evaluation demonstrates that this methodology identifies 92 % of the existing curbs over a distance of 3 000 meters, with a total of 96 % of curb points being correctly classified. Furthermore, the approach shows promising results in height estimation and was able to effectively classify curb categories of 3–7 cm and higher than 7 cm.

Keywords: Curb detection, mobile mapping, 3D laser scanning

1 EINLEITUNG

In den meisten Fällen dienen Bordsteine dazu, die Fahrbahn von angrenzenden Gehwegen zu trennen. An Kreuzungen und Fußgängerüberwegen werden Bordsteine oft abgesenkt, um es Menschen leichter zu machen, die Straße zu überqueren. Insbesondere im

Kontext der Barrierefreiheit ist die genaue Höhe von Bordsteinen entscheidend, da sie die Zugänglichkeit und Sicherheit für Menschen mit Behinderungen direkt beeinflusst. Für Personen, die auf Hilfsmittel wie Rollstühle oder Gehhilfen angewiesen sind, sollten

¹ Überarbeiteter und erweiterter Beitrag der Oldenburger 3D-Tage 2024.

Kreuzungen idealerweise niedrige und abgeflachte Bordsteine haben. Für Menschen mit Sehbehinderungen oder Blindheit sollten Bordsteinhöhen eine erkennbare und nutzbare Orientierung gewährleisten. Zu niedrige Bordsteine können schwer zu erfühlen und ein gefährliches Hindernis sein. Um den unterschiedlichen Interessen verschiedener Nutzergruppen gerecht zu werden und die Mobilität im öffentlichen Raum zu verbessern, wird automatisch und präzise erfasste geometrische Information über den Verlauf vorhandener Bordsteine benötigt. Leider sind diese Daten weder von den zuständigen Behörden verfügbar noch in öffentlich zugänglichen Datensätzen räumlich flächendeckend zu erhalten.

Seit mehr als zwei Jahrzehnten werden verschiedene Techniken zur automatisierten Bordsteinerkennung eingesetzt und untersucht. Abhängig von der Anwendung oder den Forschungszielen wird eine Vielzahl von Sensoren verwendet. Die häufigste Anwendung stammt aus dem Bereich des autonomen Fahrens mit Kamera- oder Light-Detection-and-Ranging-(LiDAR)-basierten Systemen. Obwohl viele Studien die Detektion von Bordsteinen bereits behandeln, schließen sie die Erfassung der Bordsteinhöhen größtenteils aus.

In diesem Beitrag wird ein Verfahren zur Extraktion von Bordsteinen und zur Bestimmung der Bordsteinhöhen vorgestellt. Als Eingangsdaten dienen LiDAR-Punktwolken, die mit einem mobilen Kartierungssystem erfasst wurden. Die Evaluation zeigt, dass das vorgestellte System in der Lage ist, großräumig den Verlauf von Bordsteinen zu erfassen und deren Höhe zuverlässig zu bestimmen.

2 DAS MOBILE KARTIERUNGSSYSTEM

Zur Aufnahme der 3D-Eingangsdaten wird ein Ouster-OS1-128-LiDAR-Sensor eingesetzt. Dieser scannt in 128 Scanlinien mit 1024 Punkten pro Ring in einem vertikalen Öffnungswinkel von 45°. Die Aufnahmefrequenz beträgt 20 Hz. Aufgrund seines geringen Gewichts von 500 Gramm kann der Laserscanner leicht von einem Menschen auf einem Helm montiert getragen werden. Dieser Aufbau ermöglicht eine kostengünstige und flexible mobile Kartierung in von Menschen zugänglichen urbanen Umgebungen. Im Gegensatz zum Scannen mit Fahrzeugen oder Drohnen werden hier die Daten somit direkt in der für den Anwendungskontext relevanten Domäne und aus kürzerer Entfernung aufgenommen, wodurch eine

höhere Punktdichte erreicht wird als beim schnellen Fahren oder beim Scannen von einer Drohne aus größerer Entfernung.

Für die Datenerfassung wird eine TSDF-SLAM-Software verwendet [Eisoldt et al. 2022]. Dabei werden die eingehenden LiDAR-Scans gegen eine implizite flächige Repräsentation der gescannten Oberflächen registriert, einem sogenannten Truncated Signed Distance Field (TSDF), das auf einem Voxelgitter repräsentiert wird. Dies erlaubt mittels GPU-beschleunigten Algorithmen eine Datenintegration in Echtzeit. Dazu kommt ein NVIDIA Jetson Orin zum Einsatz. Der TSDF-SLAM-Algorithmus registriert die Daten inkrementell. Anschließend wird mittels Voxelized Global ICP (VGICP) eine globale Optimierung vorgenommen. Dies erhöht die Registrierungsgenauigkeit erheblich, benötigt aber viel Rechenzeit. Um das System echtzeitfähig zu halten, wird dieser Schritt nur dann ausgeführt, wenn das Zeitfenster ausreicht. Details zum Algorithmus finden sich in [Gaal et al. 2023].

Die Verbindung zwischen dem Ouster-Sensor und dem auf Ubuntu basierenden Host erfolgt über das Robot-Operation-System (ROS). Die Speicherung der registrierten LiDAR-Daten erfolgt in ROS-Bag-Dateien. Um die Qualität der zu erwartenden Daten zu beurteilen, wurden zunächst die Eingangsdaten des Ouster-Scanners mit einem hochauflösenden RIEGL VZ-400i verglichen. Das mobile Scanning-System und die verglichenen Punktwolken sind in *Abb. 1* dargestellt. Es zeigt sich, dass die Daten des Ouster im Vergleich zum terrestrischen Laserscanner deutlich mehr Rauschen aufweisen. Aufgrund der dennoch gut erkennbaren Straßen- und Gehwegebenen ist eine Segmentierung und Höhenbestimmung unter Verwendung robuster Klassifikationsverfahren möglich, wie in den folgenden Abschnitten beschrieben.

3 STAND DER TECHNIK UND ANGEWENDETE METHODEN

Eine häufig verwendete Methode zur Bordsteinerkennung ist die Hough-Transformation. Diese kann innerhalb der Punktwolke, einer Scanlinie oder auf einem Digitalen Höhenmodell (DEM, Digital elevation model) angewendet werden. Da der Sensor, der in diesem Beitrag verwendet wird, kreisförmige Scanlinien aufzeichnet, kann die Detektion der längsten Geraden innerhalb einer Scanlinie nicht

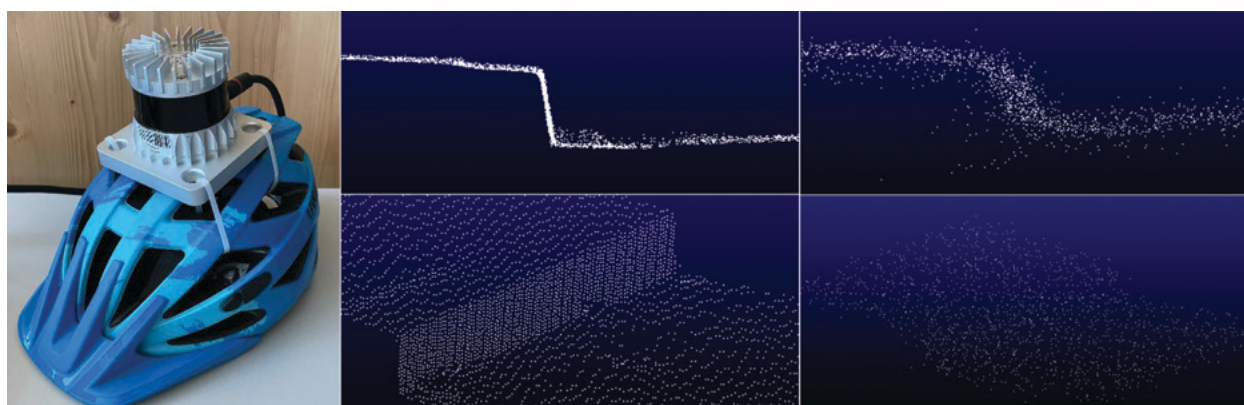


Abb. 1 | Der auf einem Fahrradhelm montierte 3D-Scanner und Punktwolken zur Bordsteinerkennung. Das Bild in der Mitte zeigt die Punktwolke eines terrestrischen Laserscanners, das rechte die mit dem mobilen Messsystem erzeugten Daten.

angewendet werden. Die Linienabschnittsanalyse von /Shin et al. 2010/ hat das gleiche Problem. Darüber hinaus ist eine Ausrichtung der Linien zur Fahrtrichtung erforderlich, was ein weiteres Ausschlusskriterium für die hier dargestellte Anwendung ist. Bild- oder DEM-basierte Hough-Ansätze, wie die von /Liu et al. 2013/, sind ebenfalls ungeeignet, da nur gerade Bordsteine erkannt werden, während gebogene Bordsteine nicht sicher detektiert werden können.

Im Gegensatz zu den linienbasierten Analysen stützen sich die auf „Conic Section Compression“ basierenden Verfahren, z. B. /Guerrero et al. 2020/, auf Daten von 3D-Sensoren, die kreisförmige Scanlinien aufzeichnen – analog zu dem in diesem Beitrag verwendeten Sensor. Die Schwäche dieser Herangehensweise besteht allerdings darin, dass bei geneigtem und nicht horizontalem Boden sowie bei unebenem Gelände, wie grobem Kopfsteinpflaster, elliptische und verformte Scanlinien anstelle der kreisförmigen Scanlinien erzeugt werden. Dies schränkt die Zuverlässigkeit der Methode stark ein. In Bezug auf das eingesetzte Kartierungssystem dieser Arbeit besteht der größte Nachteil bei diesen Ansätzen jedoch darin, dass ein fester Winkel relativ zur Sensorplattform die Grundvoraussetzung ist. Das in diesem Beitrag eingesetzt Helmsystem befindet sich jedoch aufgrund der natürlichen Kopfbewegung während der Vermessung in einer ständig wechselnden Orientierung relativ zum Boden, was bedeutet, dass erstens keine idealen kreisförmigen Scanlinien erzeugt werden und zweitens keine Merkmale wie Winkel oder die Abstände zwischen je zwei benachbarten Ringen vorberechnet werden können.

Für den Klassifikationsansatz unter Verwendung von Bayes-Filtern sind vordefinierte Bordsteinmodelle mit fester Breite und Höhe erforderlich. Die Haar-Wavelet-Transformation von /Peterson et al. 2008/ beispielsweise erfordert explizites Wissen über Kreuzungen und ihre Geometrie, wobei die Autoren auf GIS-Daten verweisen. Andere Bordsteinerkennungen wie die von /Zai et al. 2018/ verwenden häufig Trajektorien aus dem mobilen Scanning-System zur Straßenextraktion. In /Oniga et al. 2008/ wird eine zeitliche Filterung unter Verwendung mehrerer Frames angewendet, bei der die Autoren ein DEM aus mehreren Frames erstellen, um Fehler und Rauschen zu reduzieren und die Genauigkeit des DEM zu verbessern. Dieser Ansatz wäre mit dem in diesem Beitrag verwendeten System kompatibel, jedoch müssten diverse Metadaten, z. B. Zeitstempel, vorgehalten werden. Wir bevorzugen aus zwei Gründen eine Bordsteinerkennungsmethode, die nur 3D-Koordinaten verarbeitet. Erstens kann sie einfacher auf andere Sensoren und mobile terrestrische LiDAR-Systeme angewendet werden. Zweitens kann eine solche Methode bereits gesammelte Daten für die Bordsteinerkennung aus anderen Anwendungen aufbereiten.

Neben solchen „klassischen“ Verfahren gibt es auch Verfahren, die auf Deep-Learning-Methoden basieren. Ein bekanntes Beispiel ist PointNet++ von /Qi et al. 2017/. Aus eigenen Vorarbeiten mit RandLA-Net /Mitschke et al. 2022/ wissen wir, dass diese bei der Klassifikation von einzelnen, gut segmentierbaren Objekten oder großflächiger Strukturen, wie Wänden, Dachflächen und Bodenebenen, gute Ergebnisse liefern. Da wir in unserer Arbeit aber auch an der Bestimmung der Höhe der Bordsteine interessiert sind, müssten für verschiedene Höhenstufen unterschiedliche Klassen gelernt und in den Daten annotiert werden, um eine der PointNet-Varianten

nutzen zu können. Auch die Anwendung von Foundation-Modellen wäre eine Alternative. Diese eignen sich allerdings besser zur Segmentierung als zur Klassifikation /Moenk & Schüppstuhl 2025/. Daneben gibt es auch Methoden wie beispielsweise CurbNet /Zhao et al. 2025/, die spezialisierte Feature-Vektoren zur Klassifikation benutzen. Im Prinzip sollten diese auch aufgrund der einheitlichen Struktur von Bordsteinverläufen in unterschiedlichen Szenen gut auf neue Umgebungen skalieren. Allerdings sind die in /Zhao et al. 2025/ gezeigten Ergebnisse nur auf den Benchmark-Datensätzen vergleichbar gut wie die klassischen Ansätze. In realistischen Szenarien waren die Ergebnisse allerdings deutlich schlechter. Daher haben wir uns – insbesondere, weil wir auch an der direkten Bestimmung der Bordsteinhöhe interessiert sind – in dieser Arbeit für eine rein geometrische Klassifikation entschieden.

4 ALGORITHMUS ZUR BORDSTEINEXTRAKTION

4.1 Datenstruktur

Ein häufiges Problem bei der Verarbeitung von 3D-Punktwolken ist der Umgang mit der großen Menge von LiDAR-Punkten. Diese sind nicht strukturiert und liefern keine direkte Darstellung des freien oder unbekanntes Raums. Dies macht den gezielten Zugriff auf einzelne Punkte oder Punktnachbarschaften komplex und schwierig. Da sich diese Arbeit mit städtischen Szenen beschäftigt, bei denen die Straße, der Gehweg und der dazwischenliegende Bordstein im Mittelpunkt der Untersuchung stehen, kann angenommen werden, dass die untersuchten Merkmale in erster Linie in einer horizontalen 2D-Beziehung stehen. Eine Datenstruktur, die gut zur Darstellung von 2D-bezogenen Merkmalen geeignet ist, sind pixelbasierte Raster. Allerdings geht die Rasterung mit dem Verlust von 3D-Informationen einher. Um dies zu vermeiden, wurde eine punktbasierte Gitterstruktur verwendet, die es erlaubt, 3D-Daten in einem 2D-Raum zu verarbeiten.

Zu diesem Zweck wird für jeden Punkt eine Rasternummer in x - und y -Richtung per Modulo-Shift auf ein Gitter der Zellgröße s berechnet. Um einen effizienten und einfachen Zugriff auf die Gitterpunkte in den folgenden Algorithmen zu ermöglichen, werden alle Punkte zuerst nach ihrer Rasternummer in x -Richtung, dann nach ihrer Rasternummer in y -Richtung und schließlich nach ihren Höhen in aufsteigender Reihenfolge sortiert. Dadurch wird erreicht, dass alle Punkte in einer Zelle durch nur zwei Indizes ausgewählt werden können. Der erste Index bezieht sich auf den Anfang der Zelle und der zweite Index bezieht sich auf den letzten Punkt der Zelle. Mit dieser Speicherung ist es möglich, auf jede Zelle unabhängig von anderen Zellen zuzugreifen und diese zu untersuchen. Je nach Rasterabstand enthält jede Zelle nur wenige markante Merkmale, wodurch die Unterscheidung der Zellen untereinander erleichtert wird. Gleichzeitig ist es möglich, zusätzliche Informationen aus benachbarten Rasterzellen zu sammeln, um zu prüfen, ob ein Merkmal über die Grenzen einer Zelle hinaus existiert. Für Letzteres kann die Nearest-Neighbourhood-Methode zellenweise angewandt werden, wobei aber weiterhin auf jeden einzelnen Punkt zugegriffen werden kann /Belton et al. 2010/.

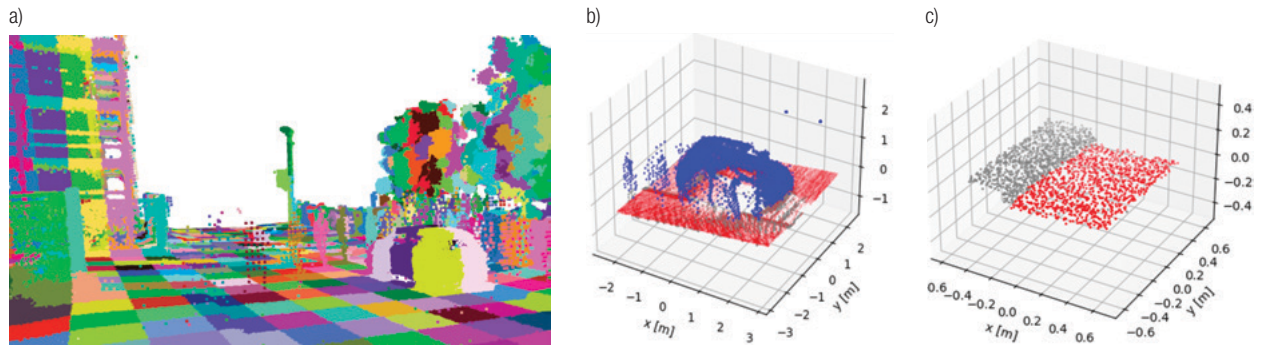


Abb. 2 | 3D-Punktwolke in 2D-Rasterstruktur (a), zellenweise grobe Selektion der tieferen Punkte (blau) (b), zellenweise RANSAC-Inlier (rot) und Outlier (grau) (c)

Schließlich ist zu erwähnen, dass die Ausrichtung des Koordinatensystems einen direkten Einfluss auf die Berechnung der Rasternummern hat. Wenn die Koordinatenachse z.B. schief ist, werden die berechneten Rasternummern und die Höhensortierung verzerrt. Dennoch bleiben die Vorteile der allgemeinen Gitterstruktur erhalten. Daher wählen wir mittels PCA ein lokales Koordinatensystem, das die Daten bestmöglich beschreibt, um bei der Höhenbestimmung unabhängig von der Orientierung eines globalen Bezugssystems zu sein. Eine Visualisierung der resultierenden Datenstruktur ist im linken Bild von *Abb. 2* gezeigt.

4.2 Die Bordsteinerkennungspipeline

Bordsteinerkennungspipelines sind Abfolgen von Schritten, die zur Bordsteinerkennung eingesetzt werden. Zu Beginn der Pipeline werden häufig Techniken zur Rauschfilterung und zur Segmentierung zwischen Boden und Nicht-Bodenpunkten eingesetzt. Teilweise wird auch eine präzisere Unterscheidung zwischen Straße und Nicht-Straße vorgenommen. Anschließend werden die geometrischen Merkmale selektiv für einen begrenzten Satz von Punkten, häufig Straßen- oder Bodenpunkte, extrahiert. Danach folgt eine Auswahl von sogenannten Kandidatenpunkten, die potenziell Teil eines Bordsteins sein könnten. Die Auswahl der Kandidatenpunkte erfolgt oft basierend auf verschiedenen Annahmen, wie Bordsteine in der Umgebung angeordnet sind. Zum Beispiel könnten Kandidatenpunkte solche sein, die sich entlang der Kanten der Straße befinden oder eine bestimmte Höhenschwelle überschreiten. Diese Punkte werden dann weiteren Analyse- und Verarbeitungsschritten

unterzogen, um festzustellen, ob sie tatsächlich zu einem Bordstein gehören. Die geometrischen Merkmale Krümmung, Normalenvektoren und abrupte Höhenänderungen sind die häufigsten Merkmale, die bei der Bordsteinerkennung verwendet werden. Alle drei geometrischen Merkmale können sowohl in Scanlinien als auch in einer registrierten Punktwolke, Gittern oder in Voxeln verwendet werden.

Die in dieser Arbeit verwendete Methodik basiert auf dem Verfahren aus /Belton et al. 2010/. Darin schlagen die Autoren eine Methode vor, um den 2D-Querschnitt des Bordsteins in terrestrischen LiDAR-Daten zu extrahieren. Durch den Einsatz des mobilen Kartierungssystems ist es notwendig, einzelne Verarbeitungsschritte anzupassen und zu erweitern. Im Folgenden werden nur die wichtigsten methodischen Unterschiede zum Basiskonzept von /Belton et al. 2010/ genauer erläutert.

Aufgrund der instabilen Position des mobilen Kartierungssystems und der im Vergleich zu TLS-Daten geringen Genauigkeit kann der ursprüngliche Ansatz, der auf der Analyse der Änderungen der Punktdichte entlang der vertikalen Achse basiert, nicht genutzt werden. Stattdessen erfolgt zunächst eine grobe Selektion der tieferen Punkte und anschließend ein RANSAC-Filter, um zellenweise planare Punkte zu finden (dargestellt in den rechten Bildern in *Abb. 2*). Hierbei wird ein strenger Distanz-Schwellenwert verwendet. Dadurch werden in Zellen, welche Straßen- und Gehwegpunkte beinhalten, beide Höhenebenen voneinander getrennt, da entweder die Straßenpunkte oder die Bordsteinpunkte als RANSAC-Inlier extrahiert werden. Hiernach wird die Punktwolke in kontinuierliche Regionen unterteilt. Benachbarte Zellen werden iterativ miteinander verglichen. Wenn die Normalenrichtungen der RANSAC-Inlier ähnlich und die Punktebenen nominell ausgerichtet sind, werden die

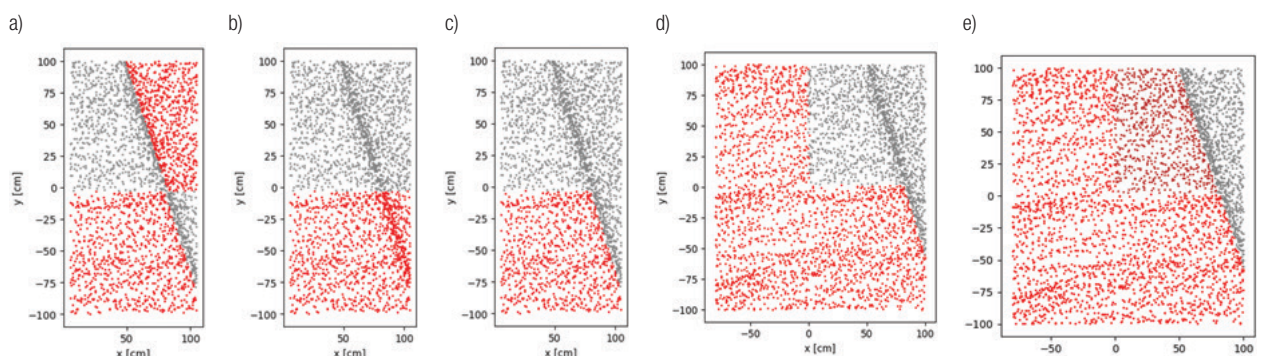


Abb. 3 | Bodenpunkte (a), Punkte einer Straßenzelle (b) und Straßenpunkte (c), jeweils markiert in Rot. Straßenpunkte in Rot und Dunkelrot vor (d) und nach (e) der Klassifizierung im Hinblick auf die Eigenschaften der Bodenpunkte in benachbarten Zellen.




Abb. 4 | Das Raster nach der Medianfilterung mit binären Klassen (a), die mit Canny-Edge extrahierten Kanten (b)

Zellen als dieselbe Region gekennzeichnet. Sobald dieses Region Growing abgeschlossen ist, werden die Zellen der größten Region als Straßenregion und alle darin befindlichen Bodenpunkte als Straßenpunkte klassifiziert. Dieses Verfahren ist in *Abb. 3 (a) bis (c)* dargestellt.

Im nächsten Schritt werden alle Zellen, die nicht als Straße markiert sind, aber an mindestens einer Straßenzelle angrenzen, hinsichtlich der Eigenschaften der RANSAC-Inlier in benachbarten Straßenzellen untersucht. Jeder Punkt innerhalb eines definierten Abstands zur RANSAC-Ebene der als Straße markierten Zelle wird dabei ebenfalls als Straßenpunkt gekennzeichnet (*Abb. 3 (d) und (e)*).

Nachdem die Straße identifiziert wurde, erfolgt die Identifikation potenzieller Bordsteinpunkte, sogenannter Kandidatenpunkte, die auf der Annahme beruht, dass sie sich am Straßenrand befinden. Hierfür werden die 3D-Punktclouden in die binären Klassen Straße und Nicht-Straße eines 2D-Rasters überführt, woraufhin die Canny-Methode zur Kantendetektion angewendet wird (*Abb. 4*). Danach wird die extrahierte Kante in die 3D-Punktcloud überführt.

Anschließend werden im geringen Zentimeterabstand geglättete Punktnachbarschaften entlang der Kante gebildet, welche genauer auf Bordsteine und deren Höhe untersucht werden, wie in *Abb. 5* skizziert. Jede Punktnachbarschaft wird zunächst anhand der Straßenpunkte parallel zur XY -Ebene ausgerichtet. Anschließend werden punktweise Normalen und deren Winkel zum Einheitsvektor $(0,0,1)^T$ berechnet. Wenn die Normalenausrichtung eines Punktes von der Normalenausrichtung der horizontalen Straßenpunkte abweicht, wird dieser als Bordstein identifiziert.

Sind die Bordsteinpunkte entlang der Straßenkante gefunden, werden wie in /Belton et al. 2010/ beschrieben 2D-Querschnitte für

jede Punktnachbarschaft erzeugt. Daraufhin wird eine gerade Linie durch die beiden Punkte gezogen, die im Querschnitt am weitesten voneinander entfernt liegen. Der Punkt, der am weitesten über der geraden Linie liegt (Pu), wird als oberer Bordstein identifiziert, während der Punkt, der am tiefsten unterhalb der geraden Linie liegt, als unterer Bordstein (Pl) bezeichnet wird. Die Bordsteinhöhe wird dann durch Berechnung der Differenz zwischen den z -Werten von Pu und Pl bestimmt. *Abb. 6* skizziert dieses Verfahren.

Neben der 2D-Querschnitts-Höhenbestimmung wurde zusätzlich eine alternative Höhenbestimmung getestet. Diese verwendet den Durchschnitt der z -Werte der Straßenpunkte und den Durchschnitt der z -Werte der RANSAC-Inlier der Nicht-Straßenzelle. Es ist wichtig zu beachten, dass die Auswahl einzelner Punktsegmente an dieser Stelle nur aufgrund der vorherigen Schritte möglich ist.

5 EVALUATIONSMETHODIK

Zur Evaluation der Bordsteinerkennung wurden sieben Punktwolken aufgenommen. Alle Daten wurden von April bis Juni 2023 in Osnabrück aufgezeichnet. Um sicherzustellen, dass die vorgeschlagene Bordsteinerkennung in städtischen Szenarien weit verbreitet eingesetzt werden kann, wurden komplexe Szenen mit unterschiedlichen Eigenschaften aufgezeichnet, um eine große Variabilität in den Daten abzudecken. Die Gesamtlänge der erfassten Bordsteinkanten beträgt mehr als 3 000 Meter. Für jeden der sieben Datensätze wurde eine Ground Truth erhoben. Dazu wurden die Punktwolken in der Software CloudCompare dargestellt und Polylinien entlang der Bordsteine als Referenzdaten gezeichnet. Zusätzlich wurden für drei Datensätze



Abb. 5 | Straßenpunkte in Straßenzellen (rot) und Straßenpunkte in benachbarten Nicht-Straßenzellen (dunkelrot), Kandidatenpunkte (grau) nach Rücktransformation der extrahierten Kante in die Punktcloud




Abb. 6 | Beispiel für segmentierte Bordsteinpunkte entlang des Straßenzugs (a), (b) und die modifizierte Berechnung der Bordsteinhöhe nach /Belton et al. 2010/ anhand der höchsten und niedrigsten Punkte (c)

vor Ort Punktmessungen in Abständen von etwa 1–2 Metern durchgeführt, um die Höhe des Bordsteins zu bestimmen. Zur Bewertung der Bordsteinerkennung wird ein Vergleich der über die entwickelte Methodik extrahierten Bordsteine mit den zuvor gesammelten Ground-Truth-Daten durchgeführt. Dies erfolgt durch die Verwendung von zwei Genauigkeitsmetriken, die üblicherweise bei binären Klassifikationsproblemen verwendet werden, nämlich Korrektheit und Vollständigkeit (Gl. (1) und Gl. (2)):

$$\text{Korrektheit} = \frac{\text{Anzahl getroffener Bordsteinpunkte}}{\text{Anzahl Bordsteinpunkte}} = \frac{TP}{TP + FP}; \quad (1)$$

$$\text{Vollständigkeit} = \frac{\text{Länge getroffener Referenzlinie}}{\text{Länge Referenzlinie}} = \frac{TP}{TP + FN}. \quad (2)$$

Um die Indizes zu berechnen, wird entlang der Bordsteine der Ground-Truth-Polylinie ein Puffer gebildet. Für die Korrektheit werden die Punkte der erkannten Bordsteine, die innerhalb des Puffers liegen, abgeglichen und als „True Positive“ (TP) markiert. Die Punkte außerhalb des Puffers stellen Fehlklassifikationen dar und werden daher als „False Positive“ (FP) bezeichnet. Analog wird das Prinzip zur Ermittlung der „False Negatives“ (FN) angewendet und die Vollständigkeit errechnet. Die Pufferbreite für den Abgleich wurde auf 25 cm festgelegt, um eine angemessene Balance zwischen der Berücksichtigung gültiger Treffer und der Ablehnung von ungültigen Punkten zu gewährleisten. Abb. 7 skizziert dieses Vorgehen. Bordsteine, die durch geparkte Fahrzeuge blockiert sind, wurden manuell aus der Bewertung ausgeschlossen. Um die Höhenschätzung zu bewerten, werden die korrekt extrahierten Bordsteinpunkte und

deren Höhenkategorie mit der vor Ort gemessenen wahren Höhe verglichen. Vor dem Hintergrund der Barrierefreiheit wurden folgende Kategorien verwendet: niedrig (kleiner als 3 cm), mittel (3–7 cm) und hoch (mehr als 7 cm).

6 AUSWERTUNG DER MESSERGEBNISSE

6.1 Eigene Datensätze

Unterschiedliche Straßenumgebungen und Bordsteine wurden in verschiedenen Datensätzen erfasst, was eine umfassende Bewertung der Leistung und Robustheit des entwickelten Algorithmus ermöglicht. Es werden quantitative Resultate zur Vollständigkeit und Korrektheit des Algorithmus sowie Karten zur qualitativen Auswertung dargestellt. Die geschätzte Höhe der Bordsteine wird farblich dargestellt. Die Farben repräsentieren die Höhenklassen wie folgt: Blau für niedrige, Grün für mittlere und Rot für hohe Bordsteine.

Die Ergebnisse zeigen, dass der Algorithmus in verschiedenen Szenarien zuverlässig funktioniert. Getestet wurden: flache Bordsteine bis hohe Bordsteine, quadratische Profile bis runde Profile, verschiedene Bordsteinzustände und Texturen, glatte asphaltierte Oberflächen bis unbehauene Kopfsteinpflaster, horizontale bis geneigte Straßen, schmale und breite Gehwege, Straßen-angrenzende Vorgärten und Vegetation, dynamische Hindernisse wie Fußgänger und Autos und schließlich statische Hindernisse wie geparkte Autos (Abb. 8).




Abb. 7 | Das Abgleichprinzip zur Klassifikation von Borsteinen, reproduziert nach /Heipke et al. 1997/, und das verwendete Messinstrument

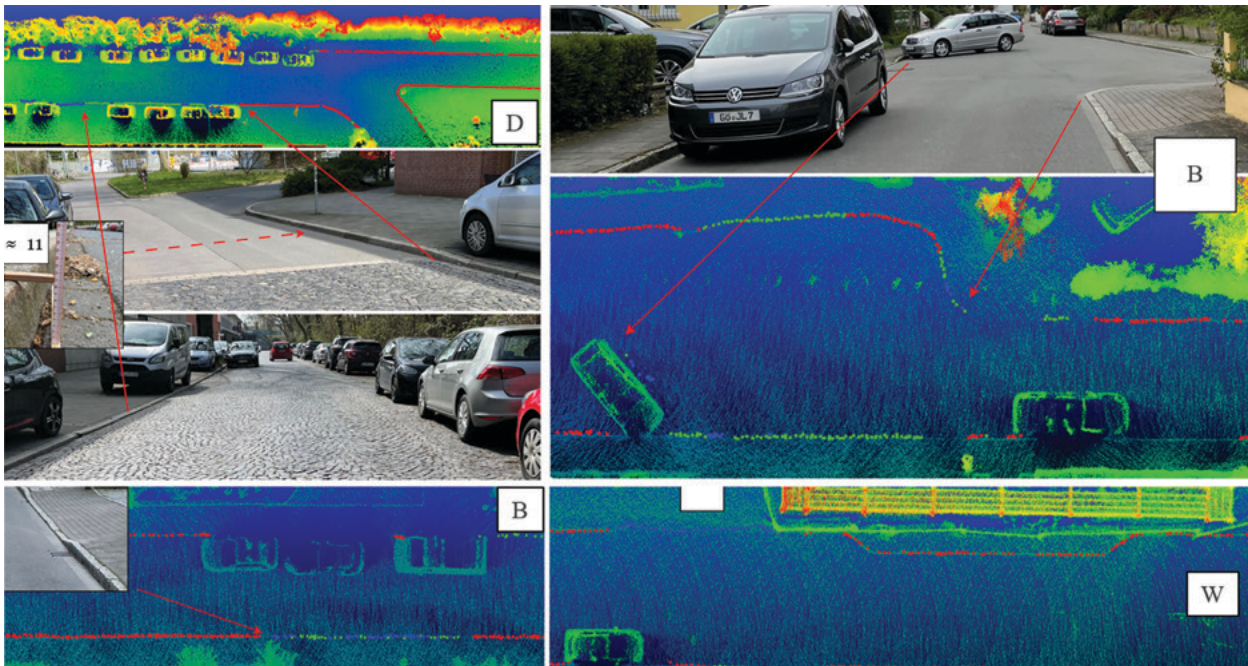


Abb. 8 | Ergebnisse der Bordsteinerkennung und Höhengschätzung der Dammstraße (D), Beethovenstraße (B) und Winkelhausenstraße (W)

In den Datensätzen „Richardstrausweg“ und „Beethovenstraße“ wurden über 92 % der Bordsteinpunkte korrekt erkannt, wobei etwa 97 % der klassifizierten Punkte mit den Ground-Truth-Daten übereinstimmten. Für die Datensätze „Mendelssohnweg“ und „Loeweweg“ mit hohen Bordsteinen um 8–10 cm erreichte der Algorithmus eine Genauigkeit von über 97 % bei der Bordsteinerkennung. Die Ergebnisse sind vergleichbar mit denen aus der „Beethovenstraße“, obwohl die Datensätze „Mendelssohnweg“ und „Beethovenstraße“ mehr Fahrzeuge enthielten. Der Datensatz „Dammstraße“ mit unebenem Kopfsteinpflaster wurde ebenfalls erfolgreich verarbeitet, wobei über 95 % der Bordsteinpunkte korrekt erkannt wurden. Weitere Ergebnisse sind in *Tab. 1* zusammengefasst.

Bei der Höhengschätzung des „Flohstraße“-Datensatzes erreicht die Durchschnittsmethode eine Genauigkeit von etwa 90 %, während die 2D-Querschnittsmethode niedrigere Werte von etwa 70 % aufwies. Die Höhenggenauigkeit des „Winkelhausenstraße“-Datensatzes mit ideal gestalteten Straßenoberflächen ist nahezu identisch für beide Methoden, wobei etwa 98 % der als hoch klassifizierten Bordsteine mit den Referenzdaten übereinstimmten. Die „Mendels-

sohnweg“-Daten sollten ursprünglich für die Bewertung der Bordsteinhöhen dienen, jedoch ergab die Datenerhebung Schwierigkeiten bei der eindeutigen Zuordnung von Bordsteinabsenkungen der niedrigen oder mittleren Kategorien. Die Bewertung konzentriert sich daher auf die Hochkategorie, bei der etwa 95 % der als hoch klassifizierten Bordsteine korrekt identifiziert wurden. Generell verdeutlichen die Ergebnisse die Herausforderungen bei der Detektion der oberen und unteren Bordsteinkanten innerhalb des 2D-Querschnitts, was vor allem durch die Punktdichte und Datenqualität sowie die Abhängigkeit vom Profil der Bordsteine und den jeweils angrenzenden Gehwegen begründet ist. Dies führt bei der 2D-Querschnittsmethode im Vergleich zur Durchschnittsmethode zu schlechteren Ergebnissen. Unter idealen Bedingungen jedoch sind beide Höhenbestimmungsmethoden als gleichwertig anzusehen.

6.2 Vergleich mit anderen Algorithmen

Wie in Abschnitt 3 ausgeführt, gibt es in der Literatur verschiedene unterschiedliche Ansätze zur Detektion und Klassifikation von

Datensätze	Bordsteinerkennung			Höhenbestimmung		
	Vollständigkeit	Korrektheit	L	Höhe	2D-QS	Durchschnitt
Richardstrausweg	89,19 %	92,45 %	860,5 m			
Beethovenstraße	92,54 %	97,97 %	556,5 m			
Loeweweg	93,35 %	97,71 %	406,5 m			
Dammstraße	89,98 %	95,78 %	279,5 m			
Flohstraße	96,26 %	96,38 %	374,5 m	3-7 cm	70 %	90 %
Winkelhausenstraße	94,72 %	94,79 %	227,5 m	> 7 cm	98 %	98 %
Mendelssohnweg	93,65 %	98,91 %	441,0 m	> 7 cm	86 %	95 %

Tab. 1 | Quantitative Ergebnisse der Bordsteinerkennung und Höhengschätzung (Vollständigkeit, Korrektheit, Länge der erfassten Strecke (L), 2D-Querschnittsmethode (QS), Durchschnittsmethode)

Verfahren	Korrektheit	Vollständigkeit	Genutzte Datensätze
Unser Ansatz	96,36 %	92,81 %	sieben selbsterstellte Datensätze
/Yan et al. 2013/	97,04 %	95,13 %	zwei selbsterstellte Datensätze
/Ye et al. 2022/	94,26 %	95,69 %	zwei selbsterstellte Datensätze
/Wang et al. 2019/	90,81 %	79,68 %	Ubudan und Kitty
/Rodríguez-Cuenca et al. 2016/	91,98 %	93,86 %	zwei selbsterstellte Datensätze
/Zhang et al. 2018/	85,07 %	82,87 %	ein eigener Datensatz

Tab. 2 | Vergleich unseres Verfahrens mit anderen Methoden. Die ausgewiesenen Werte sind jeweils die Mittelwerte aus den Datensätzen, die in den entsprechenden Papieren ausgewertet wurden.

Bordsteinen. Aus den in *Tab. 1* gezeigten Ergebnissen ergibt sich aus unseren Erhebungen eine mittlere Korrektheit von 96,36 % und eine mittlere Vollständigkeit von 92,81 % bei der Bordsteinerkennung. Um diese Werte einordnen zu können, haben wir sie vergleichbaren Methoden aus der Literatur gegenübergestellt. Da nicht für alle Verfahren freie Referenzimplementierungen vorliegen, konnten wir diese nicht auf unseren Datensätzen testen. Zur quantitativen Einordnung unserer Ergebnisse haben wir in *Tab. 2* die in den jeweiligen Arbeiten angegebenen Ergebnisse zusammengefasst.

Der direkte Vergleich zeigt, dass unser Verfahren in den meisten Fällen vergleichbar oder besser abschneidet als der Stand der Technik. Die teilweise niedrigeren Werte bei der Vollständigkeit lassen sich darauf zurückführen, dass unsere Daten in sehr herausfordernden Umgebungen mit vielen Hindernissen (geparkte Autos usw.) aufgenommen wurden und viele unterschiedliche Oberflächen inklusive Kopfsteinpflaster beinhalten, die es erschweren, alle Bordsteinverläufe korrekt zu erkennen und zu klassifizieren. Der Vorteil unserer Methode ist, dass wir keine Annahmen über den Verlauf der Bordsteine (z.B. geradlinige Ausrichtung) machen, sodass auch gekrümmte Bordsteinverläufe ausgewertet werden können.

6.3 Vergleich mit einem terrestrischen Laserscanner

Um den Einfluss der Qualität der Ausgangsdaten auf unseren Algorithmus zu adressieren, haben wir einen weiteren Datensatz mit einem hochauflösenden terrestrischen Laserscanner aufgenommen. Dabei wurde ein 120 Meter langer Abschnitt der Winkelhausenstraße mit 16 Scanpositionen mit einem Laserscanner RIEGL VZ 400i aufgenommen und registriert. Zur Auswertung wurden die Daten mit einem Voxelfilter ausgedünnt, um sie zu homogenisieren. Die so aufbereitete Punktwolke enthielt ca. 60 Millionen Punkte, ungefähr 10-mal so viele wie die mit dem mobilen Kartierungssystem aufgenommene. Die dabei extrahierten Bordsteinverläufe sind in *Abb. 9* dargestellt.

Die Ergebnisse in diesem Datensatz weichen im Ergebnis sowohl bei der Verlaufs- als auch der Höhenbestimmung um weniger als

2 % von den Ouster-Ergebnissen ab. Dies zeigt, dass unsere Verfahren zum einen auch für TLS-Daten geeignet ist. Zum anderen zeigt es auch, dass mit dem wesentlich flexibleren mobilen Messsystem vergleichbare Ergebnisse erzielt werden. Entsprechend lässt sich der Mehraufwand bei diesem Ansatz sowohl in der Scanzeit als auch in der benötigten Zeit zur nachträglichen Registrierung, bezogen auf den Qualitätsgewinn, kaum rechtfertigen.

7 ZUSAMMENFASSUNG UND AUSBLICK

Insgesamt zeigt dieser Beitrag, dass der vorgestellte Algorithmus für die Bordsteinerkennung und Höhenschätzung in verschiedenen Umgebungen robust und leistungsfähig ist. Die Ergebnisse bieten Einblicke in die Einsatzmöglichkeiten des Algorithmus und dienen als Grundlage für die Weiterentwicklung von Methoden zur Verbesserung der Genauigkeit und Anwendbarkeit in unterschiedlichen städtischen Szenarien.

Zukünftige Forschungen sollten darauf abzielen, die Identifizierung von Straßenregionen aus dem Region Growing zu automatisieren, anstatt den aktuellen Ansatz zu verfolgen, die größte einzelne Region automatisch als Straße zu kennzeichnen. Diese Anpassung hätte das Potenzial, die Robustheit des Algorithmus zu steigern und seine Anwendbarkeit signifikant zu erweitern, insbesondere für umfangreiche und komplexe städtische Umgebungen. Weitere Aspekte zukünftiger Forschung können die Untersuchung der Leistungsfähigkeit unter Verwendung unterschiedlicher Sensoren, die Prüfung der Anpassungsfähigkeit des Algorithmus an andere Datensätze wie den KITTI-Datensatz und die Erkundung potenzieller Anwendungen in Innenräumen umfassen. Darüber hinaus ist eine Vektorisierung der Bordsteinpunkte anzustreben, um Lücken, welche durch Hindernisse entstanden sind, zu schließen und um eine einfache Zusammenführung dieser Daten mit frei nutzbaren Geodatensätzen wie OpenStreetMap zu ermöglichen. Dadurch könnten die Bordsteininformationen in verschiedene Open-Source-Routing-Engines für barrierefreie Navigation integriert werden.



Abb. 9 | Extrahierte Bordsteinverläufe aus den RIEGL-VZ400i-Daten eines 120 m langen Abschnitts der Winkelhausenstraße

LITERATUR

- Belton, D.; Bae, K. H. (2010): Automating post-processing of terrestrial laser scanning point clouds for road feature surveys. In: International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences XXXVIII(2010)5.
- Eisoldt, M.; Gaal, J.; Wiemann, T.; Flottmann, M.; Rothmann, M.; Tassemeier, M.; Pormann, M. (2022): A Fully Integrated System for Hardware-accelerated TSDF SLAM with LiDAR Sensors (HATSDF SLAM). In: Robotics and Autonomous Systems (RAS) 106(2022).
- Gaal, J.; Wiemann, T.; Mock, A.; Pormann, M. (2023): FeatSense – A Feature-based Registration Algorithm with GPU-accelerated TSDF-Mapping Backend for NVIDIA Jetson Boards. In: 2023 Seventh IEEE International Conference on Robotic Computing (IRC). IEEE, 198–205.
- Guerrero, J. A.; Chapuis, R.; Aufrère, R.; Malaterre, L.; Marmoiton, F. (2020): Road Curb Detection using Traversable Ground Segmentation: Application to Autonomous Shuttle Vehicle Navigation. In: 16th International Conference on Control, Automation, Robotics and Vision (ICARCV). IEEE.
- Heipke, C.; Mayer, H.; Wiedemann, C.; Jamet, O. (1997): Evaluation of automatic road extraction. In: International Archives of Photogrammetry and Remote Sensing 32(1997)3, 151–160.
- Liu, Z.; Wang, J.; Liu, D. (2013): A New Curb Detection Method for Unmanned Ground Vehicles using 2D Sequential Laser Data. In: Sensors 13(2023)1.
- Mitschke, I.; Wiemann, T.; Igelbrink, F.; Hertzberg, J. (2022): Hyperspectral 3D point cloud segmentation using RandLA-Net. In: International Conference on Intelligent Autonomous Systems. Springer Nature Switzerland, Cham, 301–312.
- Moenk, K.; Schüppstuhl, T. (2025): Exploiting Large-Scale Pre-trained Vision Foundation Models in 3D Point Cloud Segmentation. In: allgemeine vermessungs-nachrichten (avn) 132(2025)4, 158–167. DOI: 10.14627/avn.2025.4.2.
- Oniga, F.; Nedeveschi, S.; Meinecke, M. M. (2008): Curb Detection Based on a Multi-Frame Persistence Map for Urban Driving Scenarios. In: 11th International IEEE Conference on Intelligent Transportation Systems.
- Peterson, K.; Ziglar, J.; Rybski, P. E. (2008): Fast Feature Detection and Stochastic Parameter Estimation of Road Shape using Multiple LIDAR. In: IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS).
- Qi, C. R.; Yi, L.; Su, H.; Guibas, L. J. (2017): Pointnet++: Deep hierarchical feature learning on point sets in a metric space. arXiv:1706.02413.
- Rodríguez-Cuenca, B.; García-Cortés, S.; Ordóñez, C.; Alonso, M. C. (2016): Morphological Operations to Extract Urban Curbs in 3D MLS Point Clouds. In: ISPRS International Journal of Geo-Information 5(2016)6, 93. <https://doi.org/10.3390/ijgi5060093>.
- Shin, Y.; Jung, C.; Chung, W. (2010): Drivable Road Region Detection using a Single Laser Range Finder for Outdoor Patrol Robots. In: 2010 IEEE Intelligent Vehicles Symposium, 877–882.
- Wang, G.; Wu, J.; He, R.; Yang, S. (2019): A point cloud-based robust road curb detection and tracking method. In: IEEE Access 7(2019), 24611–24625.
- Yang, B.; Fang, L.; Li, J. (2013): Semi-automated extraction and delineation of 3d roads of street scene from mobile laser scanning point clouds. In: ISPRS Journal of Photogrammetry and Remote Sensing 79(2013), 80–93.

Ye, C.; Zhao, H.; Ma, L.; Jiang, H.; Li, H.; Wang, R.; Chapman, M.; Marcato Junior, J.; Li, J. (2022): Robust lane extraction from mls point clouds towards hd maps especially in curve road. In: IEEE Transactions on Intelligent Transportation Systems 23(2022)2, 1505–1518.

Zai, D.; Li, J.; Guo, Y.; Cheng, M.; Lin, Y.; Luo, H.; Wang, C. (2017): 3-D Road Boundary Extraction from Mobile Laser Scanning Data via Supervoxels and Graph Cuts. In: IEEE Transactions on Intelligent Transportation Systems 19(2017)3, 802–813.

Zhang, Y.; Wang, J.; Wang, X.; Dolan, J. M. (2018): Road-segmentation-based curb detection method for self-driving via a 3D-LiDAR sensor. In: IEEE Transactions on Intelligent Transportation Systems 19(2018)12, 3981–3991.

Zhao, G.; Ma, F.; Qi, W.; Liu, Y.; Liu, M.; Ma, J. (2025): CurbNet: Curb detection framework based on LiDAR point cloud segmentation. arXiv:2403.16794.

AUTOREN



M. Sc. Simon Pfeil

UNIVERSITÄT OSNABRÜCK
INSTITUT FÜR INFORMATIK

Wachsbleiche 27 | 49090 Osnabrück | Deutschland
spfeil@uni-osnabrueck.de



Prof. Dr. Thomas Wiemann

HOCHSCHULE FULDA
FACHBEREICH ANGEWANDTE
INFORMATIK

Leipziger Str. 123 | 36037 Fulda | Deutschland
thomas.wiemann@informatik.hs-fulda.de | ORCID: 0000-0003-0710-872X



M. Sc. Marcel Storch

UNIVERSITÄT OSNABRÜCK
INSTITUT FÜR INFORMATIK

Wachsbleiche 27 | 49090 Osnabrück | Deutschland
marcel.storch@uni-osnabrueck.de | ORCID: 0000-0001-5726-6297

Manuskript eingereicht: 02.12.2024 | Im Peer-Review-Verfahren begutachtet