

Automatische Detektion von Substanzmerkmalen auf 3D-Fahrbahnoberflächen

Automatic Pavement Distress Detection on 3D Road Surfaces

Maximilian Sesselmann

LEHMANN+PARTNER GmbH, Dresden · sesselmann@lehmann-partner.de

Zusammenfassung: Mit Kameras und Laserscannern ausgerüstete Mobile-Mapping-Systeme ermöglichen es, digitale Topographien von Fahrbahnoberflächen schnell, flächendeckend und präzise zu erfassen. Während die Datenaufnahme weitgehend automatisiert ist, überwiegt in vielen Bereichen der Datenauswertung nach „ZTV ZEB-Stb 06“-Standard der manuelle Aufwand. So werden substanzrelevante Oberflächenschäden bislang manuell auf Basis von Kamerabildern analysiert. Die verfügbare 3D-Information wird dabei nicht mit einbezogen. Der vorliegende Beitrag zielt darauf ab, lokale Oberflächendiskontinuitäten mit geeigneten Deskriptoren zu qualifizieren und schließlich 3D-Fahrbahnoberflächen hinsichtlich geometrischer und radiometrischer Eigenschaften automatisiert zu klassifizieren.

Schlüsselwörter: Laserscanning, Zustandserfassung und -bewertung von Straßen, Maschinelles Lernen

Abstract: *Mobile mapping systems equipped with cameras and laser scanners make it possible to capture digital topographies of road surfaces quickly, comprehensively and precisely. While data acquisition is largely automated, in many areas of data analysis after German “ZTV ZEB-Stb” standard still outweighs the manual effort. So far, substance-relevant surface damage has been analyzed manually on the basis of camera images. The available 3D information is not utilized. The aim of this paper is to qualify local surface discontinuities with suitable descriptors and to automatically classify 3D road surfaces in terms of geometric and radiometric properties.*

Keywords: *Laser scanning, road distress detection, machine learning*

1 Motivation

Die Verkehrsinfrastruktur stellt einen großen Teil am Anlagevermögen des Bundes dar. Als solches steht sie stets im Fokus des politischen und öffentlichen Interesses. Vor dem Hintergrund des fortschreitenden Substanzverzehr bei der Straßeninfrastruktur sind Ausbau, Erhalt und Unterhalt des bestehenden Netzes wichtige Aufgaben für die jeweiligen Baulastträger (Kunert & Link, 2013; Bundesministerium für Verkehr und digitale Infrastruktur, 2016). Die Bestimmung des optimalen Zeitpunkts für Erhaltungsmaßnahmen kann nur durch ein solides Erhaltungsmanagement geleistet werden. Die Grundvoraussetzung hierfür ist eine möglichst detaillierte Kenntnis über den Straßenzustand. Zur systematischen, objektiven und einheitlichen Erfassung den Straßenzustand beschreibender Messdaten existiert in Deutschland die messtechnische Zustandserfassung und -bewertung von Straßen nach „ZTV ZEB-Stb 06“ – im Folgenden als ZEB abgekürzt (Forschungsgesellschaft für Straßen- und Verkehrswesen, 2006). Sie wird in festen Intervallen auf Bundesautobahnen und -fernstraßen durchgeführt. Mit Laser- und Kamerasystemen ausgerüstete Mobile Mapping Systeme sind die modernsten Erfassungssysteme, die hierbei zum Einsatz kommen. Heutige Messsysteme ermöglichen es,

digitale Topographien von Fahrbahnoberflächen schnell, flächendeckend und präzise zu erfassen. Auch wenn im Rahmen der ZEB bereits seit einigen Jahren solche dreidimensionalen Oberflächen aufgenommen werden, fließen diese bislang nur in eine profilweise Analyse der Ebenheit in Längs- und Querrichtung und somit zur Ermittlung des Gebrauchswertes einer Straße ein. Bei der Bestimmung des Substanzwertes, der sich aus der Ausprägung von Oberflächenmerkmalen, wie z. B. Rissen und Ausbrüchen berechnet, wird die 3D-Information bisher nicht einbezogen. Der vorliegende Beitrag untersucht deshalb, wie dreidimensionale Fahrbahnoberflächen, die mit einem hochpräzisen Laserscanner erfasst wurden, hinsichtlich ZEB-relevanten Substanzmerkmalen automatisiert analysiert werden können. Im Zentrum steht dabei die Hypothese, dass sich Substanzmerkmale als eine lokale Unstetigkeit der digitalen Topographie äußern und dadurch von intakten Asphaltoberflächen unterschieden werden können. Die Auswertung zielt darauf ab, Oberflächendiskontinuitäten mit einem geeigneten Deskriptor zu qualifizieren und schließlich 3D-Fahrbahnoberflächen hinsichtlich geometrischer und radiometrischer Eigenschaften zu klassifizieren.

2 Datengrundlage

2.1 Datenaufnahme: Mobile Mapping System S.T.I.E.R

Die im Beitrag untersuchten Messdaten wurden mit dem Mobile Mapping System S.T.I.E.R der Firma LEHMANN+PARTNER GmbH aufgenommen (siehe Abb. 1). S.T.I.E.R ist ein System zur Erfassung der Längs- und Querebenheit, der Textur, der dreidimensionalen Oberfläche sowie des Oberflächenbilds von Straßen und Verkehrsflächen. Die Kernkomponenten von S.T.I.E.R sind ein Positionierungssystem, Laserdistanzsonden zur Messung von Ebenheit und Texturparametern, ein Laserscanner sowie verschiedene Kamerasysteme zur Erfassung der Fahrzeugumgebung und der Fahrbahnoberfläche.



Abb. 1:

Das Mobile Mapping System S.T.I.E.R mit dem Laserscanner „Pavement Profile Scanner“ des Fraunhofer-Instituts für Physikalische Messtechnik, der zentral im hinteren Bereich des Trägerrahmens montiert ist

Für diesen Beitrag sind der Laserscanner und das Positionierungssystem die relevanten Datenquellen. Bei ersterem handelt es sich um einen „Pavement Profile Scanner“ (PPS) des Fraunhofer-Instituts für Physikalische Messtechnik (Reiterer et al., 2013). Die Messgenauigkeit des PPS liegt, gemittelt über ein $10\text{ cm} \times 10\text{ cm}$ großes Oberflächenelement, im Submillimeter-Bereich. Um diese extrem hohe Präzision bei hohen Messgeschwindigkeiten zu gewährleisten, nutzt der PPS als Messprinzip das Phasenvergleichsverfahren. Wichtige techni-

sche Spezifikationen sind bei Fraunhofer (2017) zu finden. Die absolute Lagegenauigkeit der Trajektorie nach Post-Processing liegt im Mittel bei ca. 2 cm, die Höhengenaugigkeit bei etwa 5 cm (Applanix, 2015). Über die zeitliche Synchronisierung der Messungen des Positionierungssystems und des Laserscanners entsteht das grundlegende Datenprodukt für die weiterführenden Analysen: die 3D-Punktwolke. Da S.T.I.E.R für Messungen im Kontext der ZEB konzipiert ist, sind die Anforderungen an die Genauigkeit der Sensoren und die Qualität der mit ihnen aufgenommenen Daten sehr hoch. Seit dem Jahr 2012 hat das Messsystem S.T.I.E.R mit dem PPS jedes Jahr die zeitbefristete Zulassung zur Erfassung von Ebenheitsparametern durch die Bundesanstalt für Straßenwesen erhalten.

2.2 Datensatz

Der zur Analyse verwendete Datensatz wurde in Deutschland auf einer kommunalen Straße aufgenommen und umfasst insgesamt 503 Punktwolken von je 10 m Länge und ca. 4,2 m Breite. Die mittlere Befahrungsgeschwindigkeit lag bei 35 km/h mit einer Standardabweichung von 7 km/h. Die Scanfrequenz des PPS betrug ca. 800 Hz, wodurch ein Abstand zwischen aufeinanderfolgenden Scanprofilen in den 3D-Punktwolken von ca. 12 mm entstand. Ein einzelnes Scanprofil umfasst ca. 950 Messpunkte, wobei etwa alle 4,5 mm ein Scanpunkt auf einem Querprofil liegt. Somit ist jedes 10 m lange Fahrstreifensegment mit ca. 900.000 Laserscanner-Messungen repräsentiert.

3 Methode

3.1 Verwendete Software und Bibliotheken

Der im Folgenden vorgestellte Workflow wurde mithilfe von Freier und Open-Source-Software umgesetzt. Alle 3D-Operationen wurden dabei mit der „Point Cloud Library“ Version 1.7.1 (Rusu & Cousins, 2011) und alle Machine Learning Anwendungen mit „OpenCV“ Version 3.2.0 (Bradski, 2000) realisiert. Für die manuelle Annotation von 3D-Punktwolken wurde das freie GIS „SAGA“ (Conrad et al., 2015) und für dreidimensionale Visualisierungen die Software „Cloud Compare“ (CloudCompare, 2017) verwendet. Die angegebenen Prozesszeiten beziehen sich auf Tests im Single-Core-Modus auf einem Windows PC mit einer Intel i5 3.4 GHz DualCore CPU, 8 GB RAM und einer NVIDIA GeForce GT 630.

3.2 Lokale 3D-Punktmerkmale

Lokale 3D-Punktmerkmale ermöglichen es, lokale Geometrien in Punktwolken zu beschreiben und somit sowohl markante Punkte zu identifizieren als auch 3D-Punktwolken hinsichtlich lokaler Oberflächeneigenschaften zu kategorisieren. Es existiert eine Vielzahl von Algorithmen zur Berechnung lokaler wie auch globaler 3D-Deskriptoren. Details hierzu sind bei Tombari et al. (2010), Rusu (2010), Alexandre (2012), Aldoma et al. (2012) und Hänsch et al. (2014) beschrieben. Die vorliegende Arbeit konzentriert sich auf die Untersuchung einer Kombination zweier ausgewählter Deskriptoren im gegebenen Anwendungskontext.

Der von Rusu et al. (2009) entwickelte „Fast Point Feature Histogram“ Deskriptor (FPFH) ist eine Vereinfachung des „Point Feature Histogram“ Deskriptors (PFH). Wie bei Rusu et al. (2008) ausgeführt, zielt der dem PFH-Deskriptor zugrunde liegende Algorithmus darauf

ab, die geometrischen Eigenschaften der k Nachbarpunkte eines Punkts P_s zu codieren und mithilfe eines mehrdimensionalen Histogramms abzubilden. Der resultierende hochdimensionale Hyperraum des PFH-Deskriptors liefert eine informative Signatur der betreffenden Punktmenge, die sowohl invariant gegenüber der 6D-Pose der repräsentierten Oberfläche, als auch relativ robust gegen variable Punktdichten und Rauschpegel ist. Anders als beim PFH, werden beim FPFH nicht alle Nachbarpunktpaare berücksichtigt. Der FPFH-Deskriptor beschreibt die relative Ausrichtung von Normalen und die Abstände zwischen Punktpaaren, welche aus einem Punkt P_s und einem Punkt P_t aus dessen lokaler Nachbarschaft gebildet werden. Die Beziehung der Punktpaare wird, wie in Abbildung 2 dargestellt, durch die Winkelwerte φ , α und σ charakterisiert, die im sogenannten Darboux-Koordinatensystem berechnet werden. Anschließend werden die Winkelwerte aller Punktpaare in der lokalen Nachbarschaft in einem 11 Klassen umfassenden Histogramm jeweils für φ , α und σ abgetragen und auf einen Wertebereich zwischen 0 und 100 normalisiert, um die sogenannten Simplified Point Feature Histograms (SPFH) zu erhalten. Schließlich werden die 33 Merkmale umfassenden SPFH aller k Nachbarpunkte mit ihrer Entfernung zu Punkt P_s gewichtet, um den FPFH-Deskriptor zu berechnen (Arbeiter, 2014).

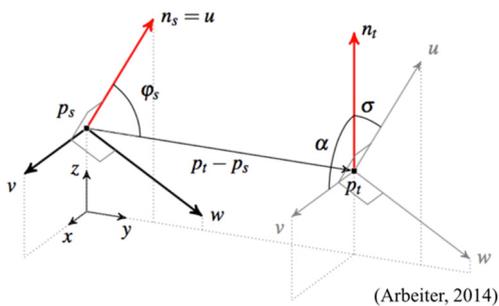


Abb. 2:
Darboux-System mit den Achsen u , v und w und den im FPFH repräsentierten Winkelwerten φ , α und σ

Ergänzt wird der FPFH-Deskriptor um einen aus dem Bereich GIS-gestützter statistischer Nachbarschaftsanalyse entlehnten und auf den 3D-Raum adaptierten Deskriptor – der „Local Statistics“ (LS) Deskriptor. Während in der klassischen Rasteranalyse ein auf jeden Eingabepixel zentriertes Kernel-Fenster die jeweilige Nachbarschaft definiert, werden im 3D-Raum Sphären mit einem bestimmten Radius um jeden Eingabepunkt aufgespannt. Für alle Nachbarpunkte des Punktes P_s wird die Spannweite der Z -Koordinaten, sowie deren Streuung in Form der Standardabweichung ermittelt. Um auch radiometrische Eigenschaften im Deskriptor abzubilden wird zusätzlich noch die Spannweite der Reflexionsintensitätswerte sowie deren Mittelwert berechnet.

3.3 Arbeitsschritte

Für Klassifikationsprobleme eignen sich im Allgemeinen neben schwellwert- und regelbasierten Methoden vor allem Methoden aus dem Bereich des maschinellen Lernens (Hastie et al., 2009). Mit 33 Merkmalen handelt es sich bei FPFH alleine bereits um einen hochdimensionalen Deskriptor, der mit dem zusätzlichen, vier Merkmale umfassenden LS-Deskriptor kombiniert wird. Daher ist hier die Anwendung eines maschinellen Lernverfahrens zur überwachten Klassifikation einer klassischen Schwellwertanalyse vorzuziehen. Für überwachte

Lernverfahren gilt, dass der Klassifikationsphase eine Trainingsphase vorausgeht, in der ein Klassifikator auf bestimmte Ausprägungen eines Deskriptors trainiert wird. In der Klassifikationsphase soll der Klassifikator auch unbekannte Ausprägungen eines Deskriptors einer bestimmten Klasse zuzuordnen können. In Abbildung 3 sind die einzelnen Datenprodukte und Arbeitsschritte schematisch dargestellt, die zur Klassifikation von 3D-Oberflächen hinsichtlich ihrer Oberflächenmerkmale führen.

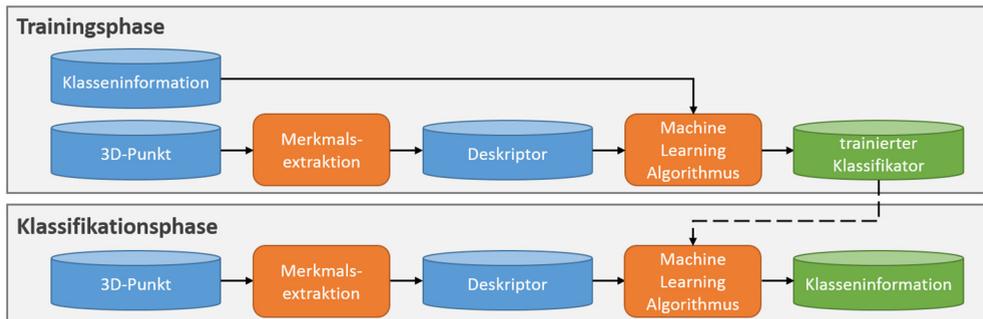


Abb. 3: Schematische Darstellung der Datenprodukte (blau), Arbeitsschritte (orange) und Ergebnisse (grün) der 3D-Oberflächenklassifikation unterteilt nach der jeweiligen Prozessphase.

3.3.1 Vorverarbeitung

Ein erster vorbereitender Verarbeitungsschritt ist das Bereinigen der rohen 3D-Punktwolke von Ausreißern. Für diese Filterung wird ein statistischer Ansatz verwendet, ein sogenannter „Statistical Outlier Removal Filter“ (Rusu & Cousins, 2011). Anschließend wird mittels lokaler Höhenspannweiten geprüft, ob eine Punktwolke gegebenenfalls Bordsteinkanten sowie daran anschließende Gehwegbereiche enthält. Sofern vorhanden, werden diese Bereiche aus der zu analysierenden 3D-Punktwolke entfernt. Dazu wird ein „3D-Region Growing“-Ansatz (Rabbani et al., 2006) genutzt, dessen Algorithmus neben der Konnektivität eine gewisse Oberflächenstetigkeit zur Bedingung hat. Solange die Winkelabweichung zwischen den Normalen zweier Punkte sowie der Unterschied ihrer Oberflächenkrümmung unterhalb definierter Schwellwerte liegen, werden sie als zum selben Punktcluster zugehörig betrachtet. Von allen Punktclustern, die der „Region Growing“-Algorithmus erzeugt, werden alle bis auf das größte Cluster verworfen. Hierbei liegt die Annahme zugrunde, dass Fahrbahnbereiche den überwiegenden Anteil der zu analysierenden 3D-Punktwolke darstellen.

3.3.2 Aufbereitung von Trainingsdaten

Um später in den Trainings- und Evaluierungsprozess einfließen zu können, müssen die verfügbaren 3D-Daten in Oberflächenklassen kategorisiert werden. Die geometrischen Eigenschaften des Zielobjekts *Straße* erlauben eine Annotation der 3D-Punkte im 2D-Raum. Mithilfe der „SAGA API“ wurden zu diesem Zweck aus den 3D-Punktclustern GIS-kompatible 2,5D-Raster erzeugt und in der „SAGA GUI“ manuell hinsichtlich folgender Zielklassen inspiziert: *intakter Asphalt*, *Risse*, *Ausbrüche*, *Markierungen* und *kleine erhabene Objekte*, wie z. B. Steine. Bei den letzten beiden Klassen handelt es sich nicht um ZEB-relevante Substanzmerkmale, jedoch sind diese Kategorien für eine automatische Klassifikation von „Nor-

malzustand versus Anomalie“ potenziell hilfreich. Risse wurden zunächst entlang ihrer Tiefenlinie als Polylinien digitalisiert und anschließend mit einem Buffer-Polygon umgeben. Der Radius betrug hierbei 2 cm. Ausbrüche, intakte Fahrbahnbereiche, Fahrbahnmarkierungen und kleine erhabene Objekte wurden direkt als Polygone digitalisiert. Insgesamt wurden 158 semantisch annotierte 2D-Trainingsgebiete erfasst. Diese wurden abschließend wieder mit den ursprünglichen 3D-Punktwolken verschnitten und somit ca. 150.000 3D-Punkte mit einer Klasseninformation gelabelt.

3.3.3 Merkmalsextraktion

Für die Berechnung des FPFH-Deskriptors existiert bereits eine entsprechende Klasse in der „Point Cloud Library“. Sie setzt eine Octree-Suchstruktur und Oberflächennormalen voraus. Der Octree wird mit 1 cm Kantenlänge auf der untersten Ebene aufgebaut. Die Normalen werden in einem Radius von 2 cm um jeden Punkt mittels Hauptkomponentenanalyse approximiert. Die Berechnung des LS-Deskriptors nutzt dieselbe Octree-Struktur und denselben, die Punktnachbarschaft definierenden Suchradius, wie der FPFH-Deskriptor. Die Berechnung des kombinierten Deskriptors für 150.000 Punkte dauert etwa 22 s. Infolge dieses Arbeitsschrittes ist jeder 3D-Punkt mit einem 37 Merkmale umfassenden Deskriptor, auch Merkmalsvektor genannt, attribuiert.

3.3.4 Maschinelles Lernen: Random Forests

Die von Breiman (2001) beschriebene Random-Forests(RF)-Klassifikation ist ein geeignetes maschinelles Lernverfahren für die Kategorisierung von Oberflächen, die durch 3D-Punktmerkmale charakterisiert sind. Im Kern handelt es sich bei RF um eine Erweiterung des klassischen Entscheidungsbaum-Modells in Form einer Kombination mehrerer eigenständiger Entscheidungsbäume. Zur Erzeugung dieser Entscheidungsbäume werden verschiedene Formen von Randomisierung genutzt, wie z. B. das sogenannte Bagging (Bootstrap-Aggregation). Nachdem jeder einzelne Entscheidungsbaum den Merkmalsvektor für sich analysiert und so zu einem eigenen Ergebnis gelangt, erfolgt die finale Klassifikation durch Mehrheitsentscheidung. Details zum RF-Algorithmus sind bei Breiman (2001), Tsymbal et al. (2006) oder Biau (2012) zu finden. Für die Wahl der RF Methode im Anwendungskontext sprechen folgende Aspekte: Erstens erfordern RF im Vergleich zu z. B. Support Vector Machines oder Neuronalen Netzen nur sehr kurze Trainingszeiten bei einer gleichzeitig geringen Anzahl freier Parameter. Darüber hinaus ist die RF-Methode aufgrund der genutzten Bootstrap-Aggregation im Vergleich zu anderen Klassifikationsmethoden resistent gegen Überanpassung und besitzt zusätzlich eine interne Fehlerabschätzung, die mit all den Trainingsdaten, die nicht zum Lernen eines Entscheidungsbaumes gewählt wurden („out-of-bag“-Daten), durchgeführt wird. Ferner bietet RF die Möglichkeit, die Information darüber zu extrahieren, wie relevant einzelne Merkmale für das trainierte Model sind.

Die RF-Klassifikation wurde unter Nutzung der entsprechenden „OpenCV“ Klassen (Bradski, 2000) implementiert, wobei zwei Variablen parametrisiert wurden: Die Anzahl der Entscheidungsbäume wurde auf 100 und die Anzahl der maximal zu verwenden Merkmale auf 37 gesetzt, wobei 33 Merkmale auf FPFH und 4 auf LS entfallen. Das Training inklusive Evaluierung dauerte für den annotierten Datensatz 235 s.

4 Ergebnisse

Im Zuge der Trainings- und Evaluierungsphase wurde vom manuell annotierten Gesamtdatensatz eine Teilmenge von 80 % isoliert, die als tatsächliche Trainingsdaten dienen. Die restlichen 20 % flossen nicht ins Training ein, sondern wurden als Validierungsdatensatz für die Evaluierung der Klassifikationsleistung separiert. Die ca. 30.000 Validierungspunkte wurden mithilfe des auf den Trainingsdatensatz trainierten Klassifikators analysiert und jedes Klassifikationsergebnis mit der manuell annotierten Klasseninformation abgeglichen. Das Ergebnis ist in Abbildung 4 in Form einer Konfusionsmatrix dargestellt. Sie visualisiert die Leistungsfähigkeit des Klassifikators in Bezug auf jede einzelne Klasse. Bei einer fehlerfreien Klassifikation über alle Klassen hinweg, würde die Hauptdiagonale der Matrix von links oben nach rechts unten die höchsten Werte aufweisen und alle anderen Zellen hätten den Wert 0. Wie aus der obigen Matrix hervorgeht, wurden Ausbrüche zu 84 %, Markierungslinien zu 99 %, intakte Bereiche zu 97 %, kleine erhabene Objekte zu 74 % und Risse zu 93 % richtig erkannt.

true label	A	710	0	2	1	123
	M	0	6009	12	0	7
	N	3	2	15239	0	338
	O	0	0	18	267	72
	R	9	10	404	1	5657
		A	M	N	O	R
		predicted label				

Abb. 4:

Konfusionsmatrix für den mit PPFH und LS Deskriptor trainierten Klassifikator (A = Ausbruch; M = Markierung; N = intakter Asphalt; O = erhabenes Objekt; R = Riss). Die Zellwerte entsprechen der Anzahl der jeweils klassifizierten 3D-Punkte des Validierungsdatensatzes.

In Ergänzung zur vorstehend beschriebenen Evaluierung wurden ganze 3D-Punktwolken aus der in Kapitel 2.2 beschriebenen Messkampagne klassifiziert und visuell-qualitativ inspiziert. Abb. 5 zeigt exemplarisch je ein gutes, ein mittleres und ein eher schlechtes Klassifikationsergebnis. Dabei fällt auf, dass der Übergangsbereich zwischen Markierungslinie und Asphaltoberfläche oft als Riss fehlklassifiziert wird. Dies lässt sich mit der tatsächlich vorhandenen Höhendifferenz von bis zu 5 mm im Übergangsbereich von Fahrbahn zu Markierung erklären. Auffällig ist auch, dass sich falsch positive Rissdetektionen eher an den Rändern der ca. 4,2 m breiten Punktwolke befinden. Der Grund hierfür ist, dass in den seitlichen Randbereichen der gescannten Oberfläche der Auftreffwinkel des Laserstrahls immer flacher und sein Footprint immer größer wird. Entsprechend können hier auch nur geringere Anteile des vom Scanner ausgesandten Signals wieder detektiert werden. Somit sind die extremen Randbereiche der Punktwolke durch eine im Vergleich zum Bereich direkt unter dem Laserscanner etwa doppelt so hohe Streuung geprägt. Deshalb wird in der konventionellen Ebenheitsanalyse im Rahmen der ZEB auch nur ein 3,2 m breiter, zentrierter Ausschnitt des Scanprofils ausgewertet. Das unterste Klassifikationsergebnis in Abbildung 5 lässt sich zusätzlich damit erklären, dass die Fahrbahnoberfläche bereichsweise von Ausmagerungen betroffen ist, wodurch sie sehr rau erscheint. Da der Klassifikator nicht explizit auf Ausmagerungen trainiert wurde, werden diese Bereiche als Riss interpretiert.

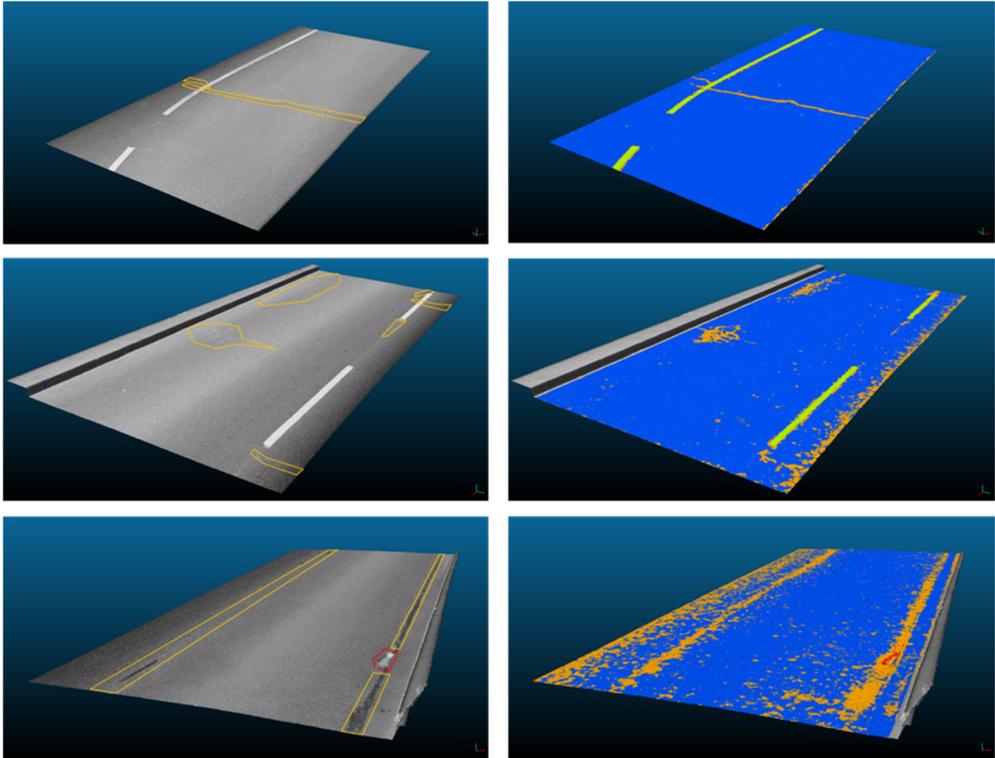


Abb. 5: Beispiele für unterschiedliche Klassifikationsergebnisse (rechte Spalte) mit von oben nach unten abnehmender Qualität (blau = intakte Fahrbahn; orange = Risse; rot = Ausbruch; grün = Markierungen). Durch die Vorverarbeitung entfernte Punktwolkenbereiche sind rechts in Graustufen dargestellt. Links sind die 3D-Punkte anhand ihrer Reflexionswerte in Graustufen dargestellt und die tatsächlich vorhandenen Schäden farblich markiert (orange = Risse; rot = Ausbruch).

Wie in Kapitel 3.3.4 beschrieben, erlaubt es die „OpenCV“-Implementierung der RF-Klassifikationsmethode, eine Aussage über die Relevanz einzelner Merkmale für die Klassentrennung zu treffen. In Abbildung 6 ist dies in Form eines Diagramms dargestellt. Die Merkmale 1 bis 33 gehören zum PPFH-Deskriptor, die Merkmale 34 bis 37 zum LS-Deskriptor.

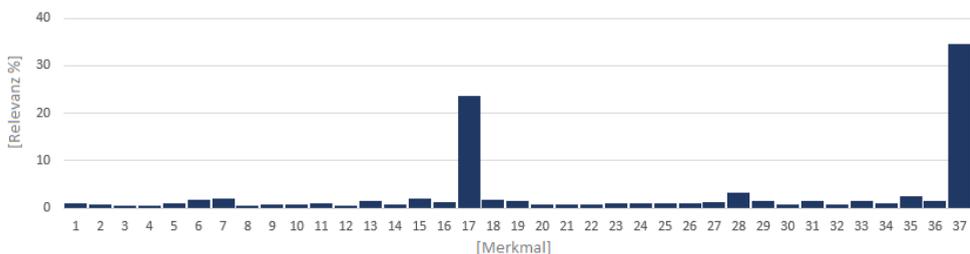


Abb. 6: Relevanz der Merkmale im Klassifikationsprozess

Nur Merkmal 36 und 37 sind radiometrischer Natur. Es lässt sich daraus ableiten, dass die Kombination der beiden Deskriptoren für die Lösung des vorliegenden Klassifikationsproblems sinnvoll ist: es werden sowohl geometrische als auch radiometrische Kriterien in den Entscheidungsprozess einbezogen.

5 Schlussfolgerung

Im vorgestellten Beitrag werden Substanzmerkmale von Fahrbahnoberflächen erstmals als geomorphometrische Objekte interpretiert und mittels 3D-Punktmerkmalen automatisiert analysiert. Die Untersuchungen zeigen, dass das Potenzial von hochauflösenden 3D-Laserscans mit einer profilweisen Analyse, wie sie im Rahmen der Zustandserfassung und -bewertung in Deutschland derzeit durchgeführt wird, nicht ausgeschöpft ist. Die Ergebnisse erlauben den Schluss, dass Risse und Ausbrüche mit den beschriebenen Deskriptoren und maschinellen Lernverfahren automatisiert detektiert werden können, wenn auch die Detektionsgenauigkeit und die Robustheit gegen unterschiedliche Oberflächen noch zu verbessern sind. Zukünftige Arbeiten werden sich deshalb darauf konzentrieren, die Trainingsdatenbasis zu erweitern und hinsichtlich der identifizierten Defizite zu optimieren sowie verschiedene Deskriptoren wie auch maschinelle Lernverfahren im gegebenen Kontext zu testen.

Literatur

- Aldoma, A., Marton, Z. C., Tombari, F., Wohlkinger, W., Potthast, C., Zeisl, B., Rusu, R. B., Gedikli, S., & Vincze, M. (2012). Point Cloud Library: Three-Dimensional Object Recognition and 6 DoF Pose Estimation. *IEEE Robotics & Automation Magazine*, 19(3), 80–91.
- Alexandre, L. A. (2012). 3D Descriptors for Object and Category Recognition: a Comparative Evaluation. *Proc. IEEE International Conf. on Intelligent Robotic Systems – IROS*, Vilamoura, Portugal, Workshop on Color-Depth Camera Fusion in Robotics (pp. 1–6). Retrieved Jan 25, 2018, from <http://www.di.ubi.pt/~lfbaa/pubs/iros2012.pdf>.
- Applanix (2015). *POS LV specifications – Mobile geospatial data acquisition*. Retrieved Jan 25, 2018, from https://www.applanix.com/pdf/specs/POSLV_Specifications_dec_2015.pdf.
- Arbeiter, G. (2014). *3-D-Umgebungserfassung für teil-autonome mobile Roboter* (Dissertation). Universität Stuttgart. <http://dx.doi.org/10.18419/opus-4572>.
- Biau, G. (2012). Analysis of a Random Forests Model. *Journal of Machine Learning Research*, 13, 1063–1095.
- Bradski, G. (2000). *The OpenCV Library*. Retrieved Jan 25, 2018, from <https://github.com/opencv/opencv>.
- Breiman, L. (2001): Random Forests. *Machine Learning*, 45(1), 5–32.
- Bundesministerium für Verkehr und digitale Infrastruktur (2016). *Bundesverkehrswegeplan 2030*. Retrieved Jan 25, 2018, from https://www.bmvi.de/SharedDocs/DE/Anlage/VerkehrUndMobilitaet/BVWP/bvwp-2030-gesamtplan.pdf?__blob=publicationFile.
- CloudCompare (2017). *Cloud Compare v. 2.9*. Retrieved Jan 25, 2018, from <https://github.com/CloudCompare/CloudCompare>.

- Conrad, O., Bechtel, B., Bock, M., Dietrich, H., Fischer, E., Gerlitz, L., Wehberg, J., Wichmann, V., & Böhner, J. (2015). System for Automated Geoscientific Analyses (SAGA) v. 2.1.4, *Geoscientific Model Development*, 8, 1991–2007. doi:10.5194/gmd-8-1991-2015.
- Forschungsgesellschaft für Straßen- und Verkehrswesen (2006). *Zusätzliche Technische Vertragsbedingungen und Richtlinien zur Zustandserfassung und -bewertung von Straßen ZTV ZEB- StB*. Köln: FGSV-Verlag.
- Fraunhofer (2017). *Pavement Profile Scanner*. Retrieved Jan 25, 2018, from <https://www.ipm.fraunhofer.de/content/dam/ipm/de/PDFs/produktblaetter/OF/LSC/Pavement-Profile-Scanner-de.pdf>.
- Hänsch, R., Weber, T., & Hellwich, O. (2014). Comparison of 3D interest point detectors and descriptors for point cloud fusion. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*. 57–64. doi:10.5194/isprsannals-II-3-57-2014.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference and Prediction* (2nd Ed.). New York: Springer.
- Kunert, U., & Link, H. (2013). Verkehrsinfrastruktur: Substanzerhaltung erfordert deutlich höhere Investitionen. *DIW Wochenbericht*, 26, 32–38.
- Rabbani, A., van den Heuvel, F. A., & Vosselmann, G. (2006). Segmentation of point clouds using smoothness constraints. *IAPRS Volume XXXVI*, Part 5, 248–253.
- Reiterer, A., Dambacher, M., Maindorfer, I., Höfler, H., Ebersbach, D., Frey, C., Scheller, S., & Klose, D. (2013): Straßenzustandsüberwachung in Sub-Millimeter. In: T. Luhmann, & C. Müller (Eds.), *Photogrammetrie – Laserscanning – optische 3D-Messtechnik: Beiträge der Oldenburger 3D-Tage 2013* (pp. 78–85). Berlin/Offenbach: Wichmann.
- Rusu, R. B. (2010). Semantic 3D Object Maps for Everyday Manipulation in Human Living Environments. *KI – Künstliche Intelligenz*, 24(4), 345–348.
- Rusu, R. B., Blodow, N., & Beetz M. (2009). *Fast point feature histograms (fpfh) for 3D registration*. Retrieved Jan 25, 2018, from <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.332.3710&rep=rep1&type=pdf>.
- Rusu, R. B., Blodow, N., Marton, Z. C., & Beetz M. (2008). *Aligning Point Cloud Views using Persistent Feature Histograms*. Retrieved Jan 25, 2018, <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.391.5915&rep=rep1&type=pdf>.
- Rusu, R. B., & Cousins, S. (2011). *3D is here: Point cloud library (PCL)*. Retrieved Jan 25, 2018, from http://www.willowgarage.com/sites/default/files/icra11_0.pdf.
- Tombari, F., Salti, S., & Di Stefano L. (2010). Unique signatures of histograms for local surface description. *Computer Vision – ECCV 2010*, 356–369.
- Tsymbal, A., Pechenizkiy, M., & Cunningham P. (2006). Dynamic integration with random forests. *European Conference on Machine Learning*, 4212, 801–808.