

Analyse von Straßenbestandsobjekten aus Laserpunktvolken durch Mustererkennung/Objekterkennung einschließlich der Georeferenzierung

FA 2.378

Forschungsstelle: LEHMANN + PARTNER GmbH, Erfurt

Bearbeiter: Großmann, A. / Störk, S. / Reiterer, A. / Scheller, S.

Auftraggeber: Bundesministerium für Verkehr und digitale Infrastruktur, Bonn

Abschluss: November 2020

1 Aufgabenstellung

Als Grundlage des Forschungsprojekts "Analyse von Straßenbestandsobjekten aus Laserpunktvolken durch Mustererkennung/Objekterkennung einschließlich der Georeferenzierung" wurden Messdaten der Mobile Mapping Fahrzeuge IRIS5 und IRIS12 eingesetzt. Die georeferenzierten Punktvolken entstanden mithilfe eines an den Fahrzeugen montierten CPS-Laserscanners vom Projektpartner, dem Fraunhofer Institut für Physikalische Messtechnik, IPM, Freiburg.



Bild 1: Bild links: Mobile Mapping Fahrzeug IRIS12 - Bild rechts: Clearance Profile Scanner CPS zur Aufnahme der Testdaten

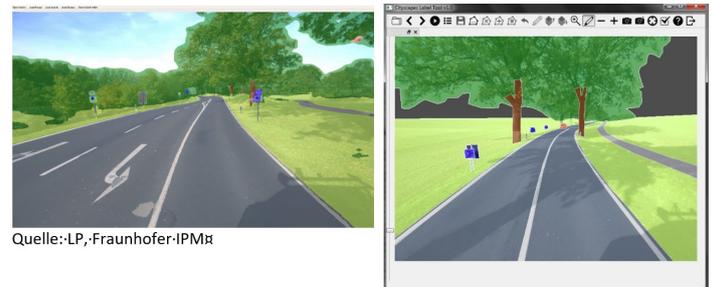
2 Untersuchungsmethodik

Die Aufgabe des Forschungsprojekts bestand in der Erforschung von Methoden und Algorithmen zur automatisierten Mustererkennung von speziellen Objekten in dreidimensionalen Punktvolken. Die ausschließliche Analyse beziehungsweise Extraktion von Objekten auf Grundlage der reinen Punktvolke erwies sich zu Beginn des Projekts als nicht zielführend. Größter limitierender Faktor war die mit der Entfernung zunehmende Dichteverringering in den Daten der Punktvolke. Dies führte zum Teil zu unterrepräsentativen Abbildungen von kleinen oder schmalen Objekten. Um dieses Defizit auszugleichen, wurden die georeferenzierten Bilddaten der Mobile Mapping-Fahrzeuge als Analysehilfe verwendet. Die Bilddaten wiesen im Vergleich zur Punktvolke ein vielfach höheres Auslösungsvermögen auf. Zur Analyse der Daten kamen verschiedene Neuronale Netze zum Einsatz, die zunächst die Bildinformationen analysieren. Für die Detektion der zuvor definierten Straßenobjekte wurden sogenannte Trainingsbilder gelabelt. Dies bedeutete, dass jeder Bereich in einer messtechnischen Aufnahme (Scene) eindeutig einem Objekt zugeordnet werden musste.

Diese Annotierung erwies sich im Nachhinein als besonders schwierig, da jeder Bearbeiter die verschiedenen Objektklassen anders generalisierte. Dies führte unter anderem dazu, dass kleinere Objekte (zum Teil im Hintergrund einer Scene) unterschiedlich gelabelt wurden, was wiederum Einfluss auf das verwendete Neuronale Netz hatte. Hierzu wurden vom Projektpartner IPM umfangreiche Tests durchgeführt, welche Netzarchitektur für eine Objekterkennung im Straßenraum sich am besten eignet. In diesem Bereich wurden zahlreiche Tests durchgeführt und auch Lösungsansätze im Zuge der Bearbeitung wieder verworfen. Nach der Trainingsphase des Neuronalen Netzes konnten Objekte einer Scene detektiert werden. Durch die georeferenzierten Bilddaten konnten alle automatisch gefundenen Objektinformationen in die Punktvolke übertragen werden. Hierbei konnte eine weitaus größere Diversität der Extraktionsergebnisse erzielt werden als mit der Analyse der reinen Punktvolke.

3 Untersuchungsergebnisse

Die finale Lösung der automatischen Extraktion bestand in der Projektion der einzelnen Objekte vom Neuronalen Netz in die Punktvolke. Dadurch, dass jedes Objekt mehrfach in jeder Bildscene erfasst wurde, wurden jedem Laserscannerpunkt mehrere automatisch generierte Objektlabel zugeordnet. Mithilfe von Clusteranalysen und Mehrheitsentscheidungen konnte die Ausgangspunktvolke in einzelne Objekte vollautomatisch zerlegt werden.



Quelle: LP, Fraunhofer-IPM

Bild 2: Bild links: Segmentierung eines Bilds aus dem Testdatensatz: Leitpfosten, Straße, Gehweg (Radweg), Markierung, Vegetation, Baumkrone und Himmel werden zuverlässig segmentiert (FCN-basiertes Netzwerk, 60 000 Iterationen). Bild rechts: manuell gelabeltes Trainingsbild für das Neuronale Netzwerk

Für die Verwendung in einem Geoinformationssystem (GIS) oder für die OKSTRA-konforme Speicherung mussten die Daten weiter aufbereitet werden. Hierzu wurden die einzelnen Objektklassen einer Repräsentationsklasse zugeordnet, sodass eine eindeutige Darstellung in einem GIS erfolgen konnte.

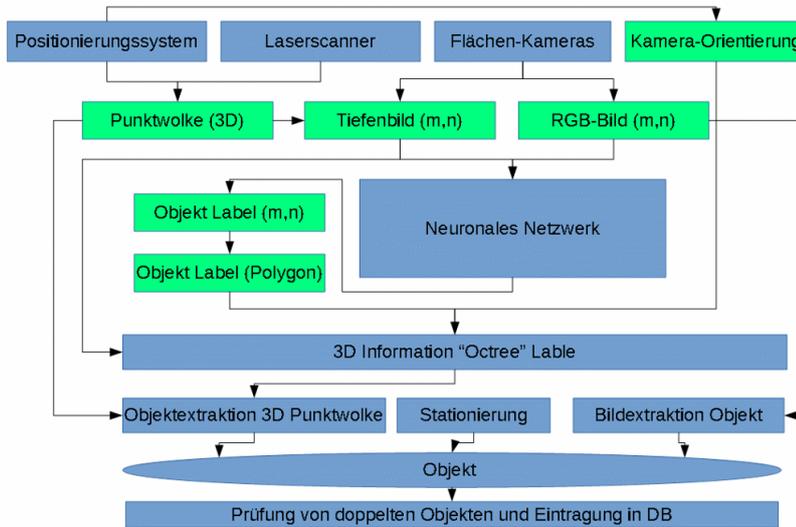


Bild 3: Semantischer Ablaufplan des Auswerteverfahrens mit Zwischenschritten und deren Beziehungen zueinander

Zur Kontrolle und Validierung der Extraktionsergebnisse wurde eine für den Auswerteprozess unbekannte Teststrecke im Raum Köln mit dem Messfahrzeug IRIS12 aufgenommen. Die Digitalisierung jedes Referenzobjekts erfolgte klassisch und ist in einer Datenbank hinterlegt. Die automatisch georeferenzierten Extraktionsergebnisse wurden ebenfalls in eine Datenbank importiert. Der Vergleich der Objekte erfolgte aufgrund Lage, Ausprägung und Objekttyp. Hierbei stellte es sich heraus, dass insgesamt 66 % der Objekte komplett oder teilweise extrahiert werden konnten. Davon konnten 26 % der Objekte mit korrektem Objekttyp und korrekter Lage, 14 % mit korrekter Lage aber falschem Objekttyp und 26 % unvollständig detektiert werden. 34 % der Objekte sind in dem automatisch detektierten Datensatz im Vergleich zum Referenzdatensatz nicht gefunden worden. Es stellte sich heraus, dass bei den Flächenobjekten nur 4 % der Referenzobjekte nicht gefunden wurden. Die kor-

rekt extrahierten Flächenobjekte konnten mit einer Erfassungsrate von 50 % in der Summe über alle Testgebiete erfasst werden. Bestes Extraktionsergebnis lieferte der Objekttyp Markierungslinien mit 90 % Übereinstimmung (Referenzdatensatz auf dem Testabschnitt der Autobahn A 3 und A 4).

Die Punktobjekte konnten in Summe nur in 47 % der Fälle mit dem Referenzdatensatz verifiziert werden. Die Zuordnungsdefizite kamen vorwiegend aus den Label-Zuordnungsfehlern, die sich zum Teil aus den Kalibrierungsdefiziten der Messsensoren und zum Teil aus der Abbildungsgeometrie schmaler und kleiner Objekte in der Punktwolke ergaben. An dieser Stelle ist festzuhalten, dass für die Verbesserung der Extraktionsergebnisse noch viel Forschungsarbeit erforderlich ist, was im Forschungsprojekt nicht realisiert werden konnte.

	Fall1	Fall2	Fall3	Fall4	Fall5
Punktobjekte	<p>Referenzobjekt mit Buffer + Autom. detektierter Punkt</p>	<p>Referenzobjekt mit Buffer ⊗ Autom. detektierter Punkt mit inkorrektem Label</p>	<p>Referenzobjekt mit Buffer ⊗ Autom. detektierter Punkt mit inkorrektem Label 0,53m</p>	<p>Referenzobjekt mit Buffer ohne Vergleichspunkt</p>	<p>Autom. detektierter Punkt ohne Referenzobjekt</p>
Linienobjekte	<p>Referenzobjekt mit Buffer — Autom. detektierte Linien</p>	<p>Referenzobjekt mit Buffer — Autom. detektierte Objekte mit inkorrektem einheitlichem Label</p>	<p>Referenzobjekt mit Buffer — Autom. detektierte Objekte mit verschiedenen inkorrekten Labeln</p>	<p>Referenzobjekt mit Buffer ohne Vergleichsobjekt</p>	<p>Autom. detektiertes Objekt ohne Referenzobjekt</p>
Flächenobjekte	<p>Referenzobjekt mit Buffer — Autom. detektierte Flächen Schnittmengen</p>	<p>Referenzobjekt mit Buffer — Autom. detektierte Objekte mit inkorrektem einheitlichem Label Schnittmengen</p>	<p>Referenzobjekt mit Buffer — Autom. detektierte Objekte mit verschiedenen inkorrekten Labeln Schnittmengen</p>	<p>Referenzobjekt mit Buffer ohne Vergleichsobjekt</p>	<p>Autom. detektiertes Objekt ohne Referenzobjekt</p>

Bild 4: Unterscheidungen zur Eingruppierung des SOLL-IST-Vergleichs zwischen dem Referenzdatensatz und dem automatisch generierten Datensatz. Hierbei wurde nach Punkt-, Linien- und Flächenobjekt unterschieden

Tabelle 1: Vergleich der Referenzdigitalisierung mit den aufbereiteten, automatisch gefundenen Objekten des Neuronalen Netzes im den zusammengefassten Bereichen Autobahn, Landstraße und Innerorts. Die Spalten mit den Extraktionsergebnissen F1-F5 sind in Bild 4 beschrieben. Die Referenz beschreibt die zugrundeliegende Prüfmenge und der Abstand die mittlere Geometrische Abweichung der einzelnen Objekte

ID	Objekttyp	Geometrie	F1 [%]	F2 [%]	F3 [%]	F4 [%]	Referenz	F5 [%]	Abstand [m]
1	Schild	Point	27.23	5.6	25.95	41.22	393	62.62	0.78
2	Kilometertafel	Point	80.00	0.00	20.00	0.00	5	16.67	0.78
3	Stationszeichen	Point	0.00	11.11	22.22	66.67	9	0.00	0.48
4	Ortsdurchfahrtszeichen	Point	0.00	20.00	40.00	40.00	5	0.00	0.39
5	Notrufsäule	Point	0.00	0.00	0.00	100.00	4	100.00	-
6	Lichtsignalanlage	Point	1.52	22.73	33.33	42.42	66	66.67	0.59
7	Beleuchtung	Point	0.00	24.14	39.66	36.21	116	28.57	1.76
ID	Objekttyp	Geometrie	F1 [%]	F2 [%]	F3 [%]	F4 [%]	Referenz	F5 [%]	Abstand [m]
8	Mast	Point	19.17	11.66	30.83	38.34	386	65.13	0.77
9	Leitpfosten	Point	14.83	4.10	5.05	76.03	317	44.00	1.00

10	Schutzplanke	Multi-Linestring	56.12	2.04	38.78	3.06	29260m	31.75	0.16
11	Schutzwand	Multi-Linestring	1.69	15.25	42.37	40.68	340m	41.06	0.29
12	Bauwerk	Polygon	65.06	28.92	4.82	1.20	6198 m ²	23.23	0.05
13	Verteilerkasten	Point	0.00	26.47	29.41	44.12	34	100.00	1.01
14	Bordstein	Multi-Linestring	0.93	9.30	61.86	27.91	1152 m	55.96	0.23
15	Deckel	Point	0.00	10.17	12.20	77.63	295	50.00	2.07
16	Fahrbahnmarkierung	Multi-Linestring	73.50	0.40	8.92	17.17	39839 m	12.83	0.15
17	Baumstamm	Point	42.33	3.43	16.70	37.53	437	59.48	1.07
18	Straße	Polygon	56.13	30.06	5.52	8.29	222079 m ²	45.02	0.09
20	Gehweg	Polygon	53.62	15.32	27.23	3.83	29773 m ²	33.30	0.03
23	Vegetation	Polygon	55.22	29.22	10.25	5.31	174322 m ²	42.60	0.05
24	Boden	Polygon	48.57	0.00	50.00	1.43	9777 m ²	0.25	0.02
26	Sperrfläche	Polygon	18.37	20.41	59.18	2.04	5004 m ²	24.82	0.02
28	Schacht	Point	2.70	6.76	9.46	81.08	148	0.00	1.61
30	Betonleitwand	Multi-Linestring	0.00	60.00	20.00	20.00	474m	74.57	0.14

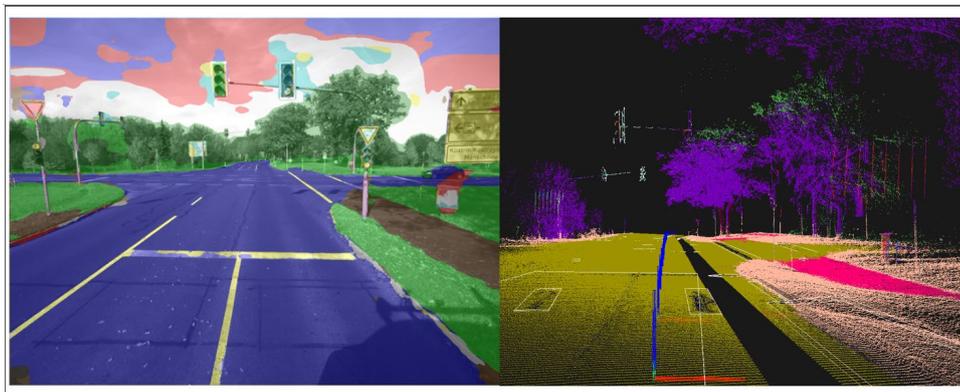


Bild 5: Bild links: automatisch detektierte Objektklassen eines Kamerabildes; Bild rechts: überführte Label Attribute in die 3-dimensionale-Punktwolke



Bild 6: Überlagerte Darstellung von Referenzdigitalisierung und automatisch extrahierten Punkt-, Linien- und Flächenobjekten (alle automatisch gefundenen Objekte sind beschriftet)

4 Folgerungen für die Praxis

Das Forschungsvorhaben zeigte, dass vollautomatische Objekte unter Zuhilfenahme von georeferenzierten Bildern der gleichen Szene aus einer Punktwolke extrahiert werden können. Im Ergebnis liegen georeferenzierte Objekte vor, die in einem GIS abgebildet werden können.