

Automatisierte Interpretation von LiDAR Mobile Mapping Daten

Claus Brenner, Fabian Bock, Alexander Schlichting
Institut für Kartographie und Geoinformatik
Leibniz Universität Hannover
Appelstraße 9a, 30167 Hannover
claus.brenner | fabian.bock | alexander.schlichting@ikg.uni-
hannover.de

1 Einleitung

In den vergangenen Jahren hat sich die detaillierte geometrische Oberflächenerfassung rasant weiterentwickelt. Sowohl die photogrammetrischen Verfahren mittels automatischer Punktzuordnung und Bündelausgleichung, als auch die LiDAR-basierten Verfahren mit direkter Georeferenzierung sind heute in der Lage, riesige Punktmengen zu gewinnen, wobei Erfassungsraten von 10^9 Punkten pro Stunde überschritten werden. Neben Verbesserungen bei den Sensorsystemen, bei LiDAR z.B. höhere Scan- (Umdrehungs-) und Pulsraten sowie verbesserte Distanzmessgenauigkeiten, sind die Erfolge auch auf allgemeine technologische Entwicklungen bei Hard- und Software zurückzuführen, die es heute erlauben, sehr große Datenmengen effizient zu speichern und zu verarbeiten.

Insbesondere haben inzwischen LiDAR Mobile Mapping Systeme beachtliche Leistungsdaten vorzuweisen, im Fall des Riegl VMX-450 beispielsweise 200 Zeilen und 550.000 Messungen pro Sekunde, je Scankopf, bei Distanzen bis zu 220 m und Messgenauigkeiten von 8 Millimetern (Riegl, 2015). Im Unterschied zu terrestrischen Scannern, die an den benötigten Standorten aufgebaut werden müssen, können diese Systeme im fließenden Verkehr betrieben werden und erzielen dadurch hohe Flächenleistungen. Zugleich erfordern sie, von der Anbringung eines Dachgepäckträgers abgesehen, keine Umbauten des Trägerfahrzeugs, so dass abgesehen vom Sensorsystem geringe Investitionen anfallen (Abb. 1).

Die technischen Entwicklungen betreffen jedoch nicht nur die Nische der geodätischen Erfassungssysteme. Beispielsweise setzt Google StreetView ein LiDAR Mobile Mapping System ein, welches LiDAR Systeme (Sick), Kameras und ein GPS/IMU System kombiniert (Anguelov et al., 2010). Die StreetView Plattformen sind sehr robust, werden in großen Stückzahlen eingesetzt, und stellen durch die immensen Datenmengen Anforderungen an die Prozessierung in bisher nicht dagewesenem Ausmaß. Beispielsweise wurde aus StreetView Daten ein globales 3D Modell berechnet, welches mehrere Millionen Straßenkilometer beinhaltet und erhebliche Teile der Erde abdeckt. Der Aufwand hierfür wird mit 2.000 Rechnerjahren (Core-Years) angegeben (Klingner et al., 2013).

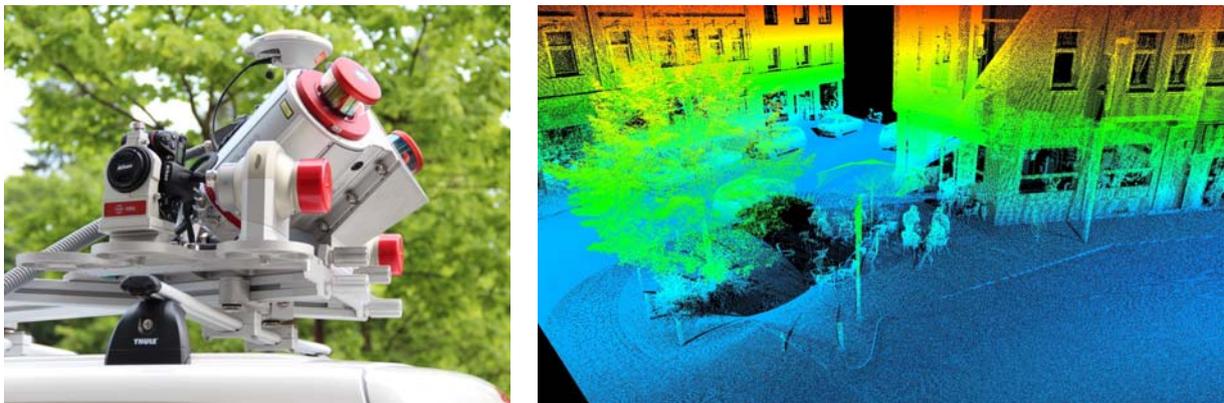


Abb. 1: Riegl VMX-250 Mobile Mapping Sensorkopf, montiert auf einem Standard-Dachgepäckträger (links), typische Punktwolke (rechts).

So beeindruckend diese Datenmengen und Prozessierungsmöglichkeiten sind, stellen sie jedoch zugleich nur den Anfang einer Entwicklung dar, die sich in den nächsten Jahren fortsetzen wird. Bereits heute sind viele Neufahrzeuge im Rahmen von Fahrerassistenzsystemen mit Sensoren ausgestattet, welche die Umgebung erfassen: Kameras, RADAR, LiDAR, sowie Ultraschall (im Nahbereich). Diese Daten werden heute üblicherweise nur für interne Fahrzeugfunktionen verwendet, etwa für das Halten der Spur, das Einhalten des Abstands zum Vordermann, die Notbremsung bei unerkanntem Querverkehr, oder für automatisiertes Einparken. Es ist jedoch bereits die Diskussion entbrannt, wem die erfassten Umgebungsdaten, die bei jeder Autofahrt anfallen, letztlich „gehören“. In manchen Bereichen, etwa bei der Ermittlung und Darstellung der aktuellen Verkehrssituation, haben sich bereits Verwertungsmodelle etabliert. Dabei werden aus den per Navigationsgerät oder Smartphone gewonnenen Positionsinformationen echtzeitnah Karten generiert, welche die Fließgeschwindigkeit des Verkehrs wiedergeben. Es ist nicht schwer, sich die Zukunft dieser als „Crowd Mapping“ bezeichneten Ansätze vorzustellen, in der Fahrzeuge neben der Ei-

genposition auch die Umgebungsinformation weitergeben, so dass zentral eine Karte gewonnen werden kann, welche die aktuelle Situation wiedergibt.

Hierbei ist von Interesse, welcher Detailgrad und welche Genauigkeit erreicht werden können. Dies sind Parameter, welche traditionell mit dem Kartenmaßstab verknüpft sind. Viel stärker als bisher tritt jedoch zudem die Aktualität in den Vordergrund. Einerseits besteht die Chance, durch einen „Crowd Mapping“ Ansatz Veränderungen in der Umgebung quasi in Echtzeit in der Karte wiederzugeben, was einer Verbesserung der heutigen Situation entspricht. Andererseits sind Assistenzsysteme, insbesondere wenn sie sicherheitsrelevante Entscheidungen treffen, auch auf hochaktuelle Kartendaten angewiesen, so dass dieser Verbesserung auch direkt neue Anforderungen gegenüberstehen.

Vor dem Hintergrund der Echtzeitfähigkeit einer Karte stellt sich die Frage, welche Objekte sie abbilden soll. Früher stellte sich die Frage des Zeithorizonts von Objekten nicht in dieser Konsequenz, da sich die Kartenerstellung in Zyklen abspielte, die durch definierte Erfassungs- und Bearbeitungszyklen (von üblicherweise mehreren Jahren) festgelegt waren. In einer „Echtzeitkarte“ sollten nach wie vor *statische Objekte*, welche tendenziell einem langfristigen Wandel unterzogen sind, der in Jahren oder Jahrzehnten bemessen wird, enthalten sein. Hierzu gehören etwa die Gestaltung der Fahrbahn, die Straßenmöblierung, Bäume und Gebäude. Daneben existieren *mittelfristig veränderliche Objekte*, etwa parkende Autos oder temporäre Baustellen, bei denen Veränderungen im Bereich von Stunden bis wenigen Tagen stattfinden. Schließlich sind *kurzfristig veränderliche (dynamische) Objekte* dadurch gekennzeichnet, dass sie sich in Bewegung befinden. Hierzu gehören etwa Fahrzeuge, Fahrradfahrer und Fußgänger, welche sich in der Szene bewegen.

Hier zeigt sich, dass der Begriff der „Karte“ verschwimmt und vielleicht eher durch den angelsächsischen Begriff der „Map“, also einer „Abbildung“ im Sinne einer „Funktion der Wirklichkeit“ wiedergegeben wird. Sicherlich ist die Idee ungewöhnlich, einzelne Fahrzeuge, Fahrradfahrer und Fußgänger in Echtzeit in einer Karte abzubilden, wengleich heute diskutierte „Car2Car“ Szenarien die Möglichkeit beinhalten, Fahrzeugpositionen und Sensordaten auszutauschen, was letztlich dieser Funktionalität entspricht. Selbst wenn man sich mit diesem Gedanken nicht anfreunden mag, lassen sich dynamische Daten auch zu zeitlich persistenteren Informationen verarbeiten, welche Eingang in eine Karte finden können. So lässt sich zum Beispiel aus einer Vielzahl von beobachteten, sich bewegenden Fahrzeugen auf die Existenz und Lage der Fahrbahn schließen.

Damit werden aus dynamischen Informationen statische Objekte abgeleitet. Ein Ansatz, der auf diesem Prinzip fußt, wird in Abschnitt 4 beschrieben.

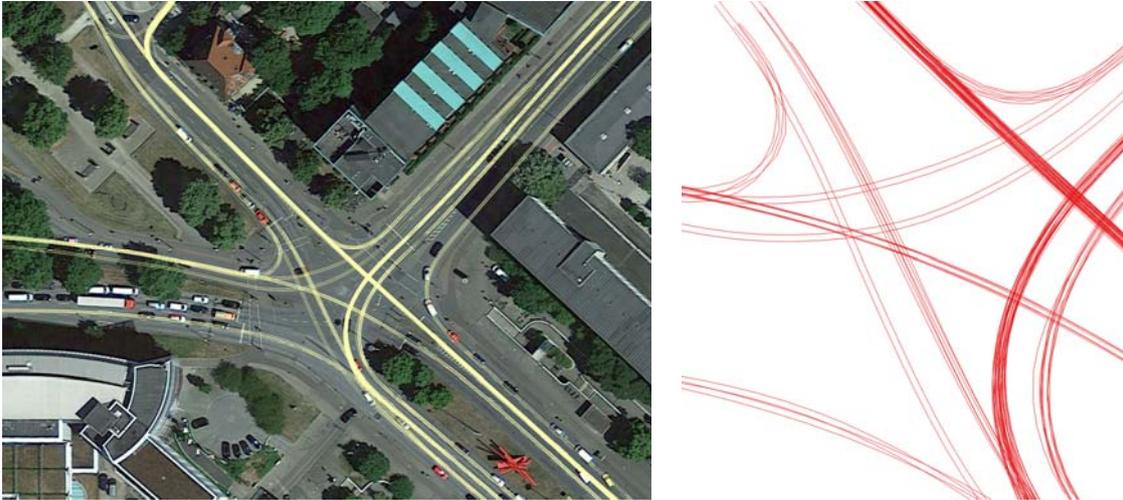


Abb. 2: Befahrungen der Kreuzung „Königsworther Platz“ in Hannover durch das ikg, Übersicht (links) und Ausschnitt in Kreuzungsmitte (rechts). Gezeigt sind die Trajektorien der (beiden) Sensorköpfe des Mobile Mapping Systems, zu denen LiDAR Scandaten vorliegen. (Luftbild © Google/GeoBasis-DE/BKG.)

Auch wenn es im Rahmen der Arbeiten eines Universitätsinstituts nicht möglich ist, Daten im „Google Maßstab“ zu gewinnen und zu prozessieren, so können doch die wesentlichen Aspekte der Interpretation von Mobile Mapping Daten im Hinblick auf neuartige Karten untersucht werden. Beispielsweise zeigt Abb. 2 die große Anzahl von LiDAR Mobile Mapping Daten, welche das ikg bislang vom „Königsworther Platz“ in Hannover gewonnen hat.

In den folgenden Abschnitten wird gezeigt, wie derartige LiDAR Mobile Mapping Daten zur Gewinnung von Informationen über statische (Abschnitt 2), mittelfristig veränderliche (Abschnitt 3) und dynamische (Abschnitt 4) Objekte genutzt werden können.

2 Statische Objekte am Beispiel von Stangen und Ebenen

2.1 Stangenförmige Objekte

Im Straßenraum sind häufig stangenförmige Objekte anzutreffen, zum Beispiel für Verkehrszeichen, Straßenbeleuchtung und Lichtsignalanlagen. Auch die Stämme von Bäumen erfüllen die Charakteristik von langgestreckten, weitge-

hend senkrechten Strukturen. Diese Objekte sind für die Eigenlokalisierung von automatisierten Fahrzeugen von Bedeutung, da sie geometrisch sehr stabil und – im Gegensatz zu Fahrbahnmarkierungen – auch bei schlechten Witterungsverhältnissen, wie etwa einer Schneedecke, stabil detektierbar sind. Ein weiterer Vorteil ist, dass sich die Lage der Stangen durch einen einzigen Zentrumspunkt sehr einfach und kompakt beschreiben lässt.

Um das Potential zu untersuchen, wurden im Rahmen einer Mobile Mapping Fahrt 21,7 Straßenkilometer befahren und die Stangen in diesem Gebiet wurden vollautomatisch extrahiert (Brenner, 2009a). Der Algorithmus hierfür geht von der Annahme aus, dass sich Stangen durch eine lineare, senkrechte Struktur im Zentrum äußern, welche in einer unmittelbaren Umgebung keine weiteren Messpunkte enthält. Zur Robustifizierung erfolgt die Auswertung in Schichten, wodurch der Einfluss von Schildern und Auslegern minimiert wird. Abb. 3 illustriert den Algorithmus und zeigt die Extrahierten Objekte in 3D und als Lagekoordinaten in einem größeren Ausschnitt des Projektgebiets.

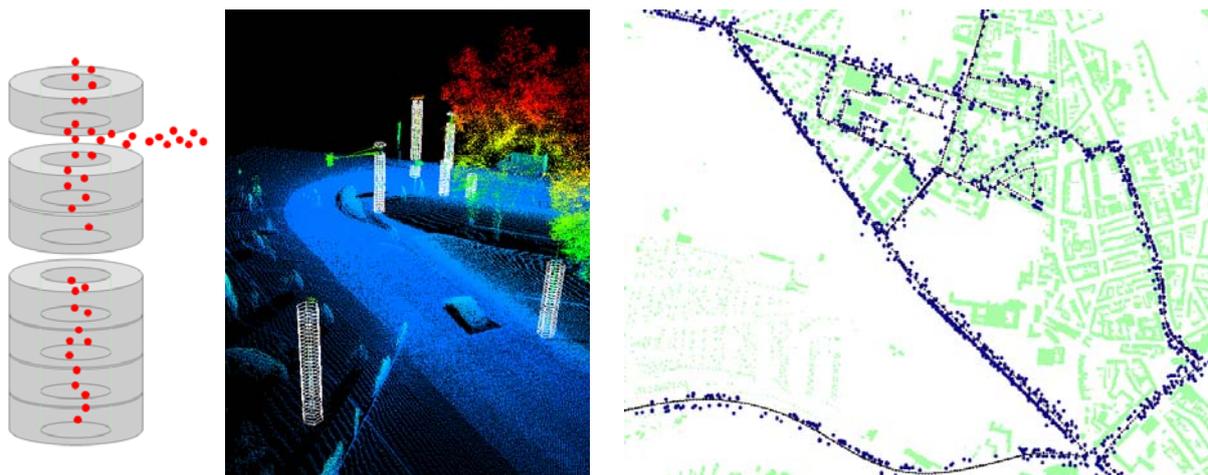


Abb. 3: Extraktionsverfahren für stangenförmige Objekte (links), extrahierte Objekte und zugrundeliegende 3D Punktwolke (Mitte), Objekte in einem Testgebiet in Hannover, überlagert einer Katasterkarte (rechts).

Insgesamt wurden vom Algorithmus im Testgebiet 2.600 Stangen gefunden. Dies ist im Schnitt eine Stange pro 8 Meter Strecke, somit wird im Vergleich zur 3D Punktwolke eine sehr große Datenreduktion erzielt. Die Reduktion der Fehldetektionen wurde in (Hofmann & Brenner, 2009) untersucht. Auf der Basis der geometrischen Anordnung der detektierten Stangen sowie von Annahmen über einen im Fahrzeug verfügbaren Sensor mit zugehöriger Genauigkeitsinformation lässt sich mittels Varianzfortpflanzung die erzielbare Lokalisierungsgenauigkeit ermitteln. Beispielsweise liegt der Darstellung in Abb. 4 die Annahme eines

„Automotive“ LiDAR Systems mit 5 cm Distanzmessgenauigkeit, 1° Winkel-messgenauigkeit (alle Angaben 1σ), einem Öffnungswinkel von 100° und einer Reichweite von 50, 100 oder 150 m zugrunde.



Abb. 4: Fehlerellipsen zur erwarteten Genauigkeit der Positionsbestimmung bei einer Maximaldistanz des Sensors von 50 m (rot), 100 m (grün) und 150 m (blau). Die Ellipsen sind 100-fach überhöht.

Durch derartige Verfahren ist es möglich, eine Karte der maximal möglichen Lokalisierungsgenauigkeit an jedem Ort zu erstellen. Diese ist einerseits optimistisch, da der Ermittlung der Positionsgenauigkeit die Annahme zugrunde liegt, dass alle Objekte im Sichtbereich des Fahrzeugsensors auch wirklich erfasst werden. Andererseits ist sie pessimistisch, weil eine Abschätzung der Genauigkeit des Einzelstandpunkts durchgeführt wurde, während in der Praxis davon ausgegangen werden kann, dass zur Stützung der Fahrzeugposition weitere Sensoren im Rahmen eines Filteransatzes kombiniert werden.

2.2 Ebenen und Merkmalskombinationen

In städtischen Gebieten sind häufig Gebäude und andere anthropogene Strukturen vorhanden, welche sich durch stückweise ebene Strukturen auszeichnen. Diese können als weitere Merkmale hinzugezogen werden. Ebenen können beispielsweise durch Region Growing (Dold & Brenner, 2004) oder robuste RANSAC (Fischler & Bolles, 1981) Ansätze vollautomatisch extrahiert werden. Zur Lokalisierung können dann Gruppen von Stangen (Hauert & Brenner, 2009) oder Kombinationen von Stangen und Ebenen (Schlichting & Brenner, 2014) verwendet werden.

Im Rahmen der Lokalisierung mittels Merkmalen stellt sich die Frage, wie eindeutig die Eigenposition ermittelt werden kann. Dies ist nicht nur wichtig für die initiale Positionsbestimmung (komplett ohne GNSS), sondern auch zur Sicherstellung einer robusten Filterlösung, welche die Fehl ASSOZIIERUNG von Merkmalen minimieren soll. Im Fall von Stangen werden die Objekte auf 2D Lagekoordinaten reduziert, hierdurch formen die Objekte Punktmuster in der Ebene. Die Aufgabe, die eigene Position zu finden, ist als „2D Point Pattern Matching Problem“ bekannt und findet Anwendung sowohl bei „Star Tracker“ Kameras für die Satellitenorientierung als auch bei der Erkennung von Fingerabdrücken (Wamelen et al., 2004). Wie sich zeigt, ist bereits eine relativ kleine Gruppe von Stangen in der Lage, eine eindeutige Positionsbestimmung zu ermöglichen (Brenner, 2009b). Die Kernpunkte sind dabei die Verfügbarkeit einer ausreichenden Anzahl von Merkmalen und die hohe Genauigkeit bei der Bestimmung der relativen Lage dieser Merkmale.

Um die Zahl der Merkmale im innerstädtischen Bereich zu erhöhen, bietet es sich an, eine möglichst detaillierte Segmentierung von Objekten vorzunehmen. In diesem Kontext haben wir ein Verfahren verfolgt, welches im Unterschied zu den meisten anderen Verfahren nicht auf der 3D Punktwolke, sondern direkt auf den Scanstreifen des Mobile Mapping Systems aufsetzt (Abb. 5).

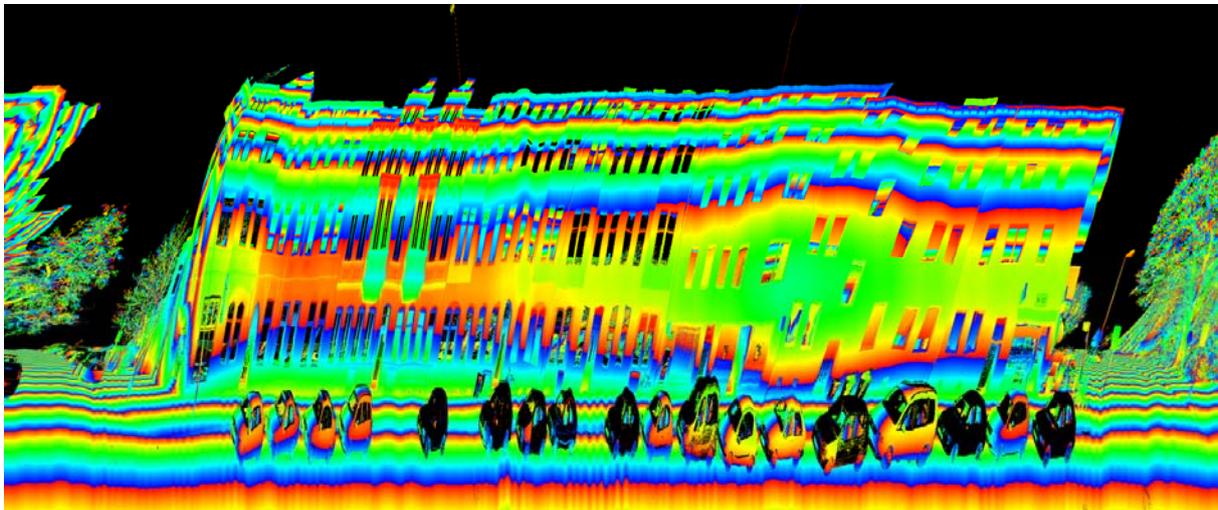


Abb. 5: Eine Straßenseite aus einem Scanstreifen des LiDAR Mobile Mapping Systems, eingefärbt nach Distanz (2 m pro Farbzyklus). Die Neigung der Objekte im Bild resultiert aus der Ausrichtung der Scanebene des Systems.

Basis des Verfahrens ist ein direkt auf dem Nachbarschaftsgitter des Scanstreifens operierendes Segmentierungsverfahren, welches einen effizienten, Graphbasierten Algorithmus verwendet, der ursprünglich zur Segmentierung von

Farbbildern konzipiert wurde (Felzenszwalb & Huttenlocher, 2004). Er zeichnet sich dadurch aus, dass sowohl Segmente mit niedriger als auch mit hoher Variabilität gefunden werden können, da sich der Parameter zur Vereinigung von Segmenten automatisch an die Daten anpasst. Wie sich zeigt, lassen sich in Verbindung mit der hohen Präzision des LiDAR Mobile Mapping Systems sehr detaillierte Segmentierungen erreichen, u.a. werden Bordsteine, Fensterlaibungen und größere Steine als individuelle Objekte erkannt.

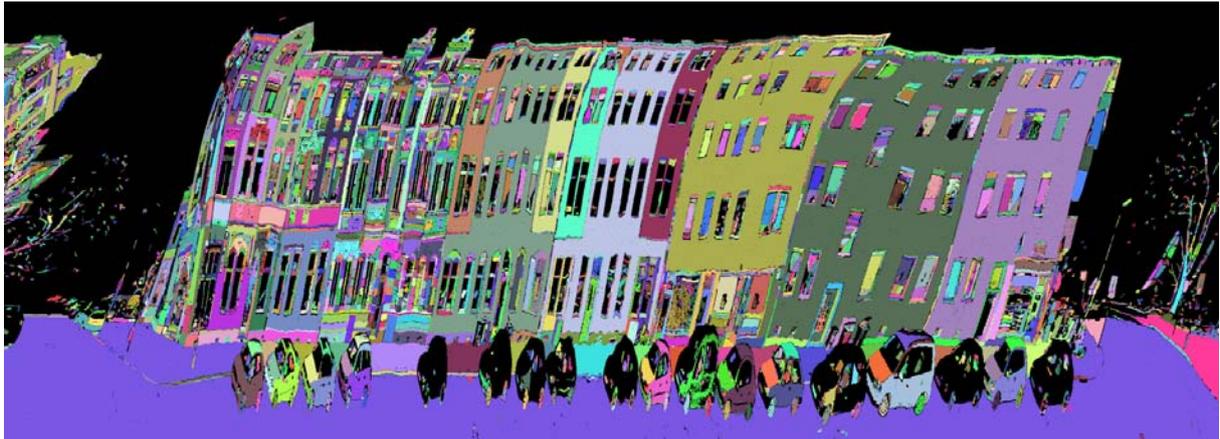


Abb. 6: Ergebnis der Segmentierung des Scanstreifens aus voriger Abbildung. Klar zu erkennen ist, dass die wesentlichen Fassadenteile erkannt werden.



Abb. 7: Details der Segmentierungsergebnisse. Links: Fensterlaibungen und gekrümmte Flächen (Unterseite des Erkers). Rechts: Bordstein und Einzelteile der Fassadestruktur bis hin zu einzelnen Steinen.

3 Mittelfristig veränderliche Objekte am Beispiel parkender Fahrzeuge

In innerstädtischen Gebieten gehört die Belegung von Parkplätzen zu den häufigsten Veränderungen, die sich auf einer Zeitskala von Stunden bis wenigen Tagen zeigen. Mit der Erfassung von geparkten Autos zu verschiedenen Zeitpunkten lassen sich nützliche Informationen für das Verkehrsmanagement ableiten. Beispielsweise können lokale Hotspots mit großer Parkplatznachfrage identifiziert oder zeitliche Charakteristiken der Parkplatzbelegung betrachtet werden. Während Parkhäuser und große Parkflächen über Schranken die Fahrzeuganzahl zählen können, ist die Erfassung für Parkplätze am Straßenrand komplexer. Eine Möglichkeit besteht darin, mit Hilfe von Mobile Mapping Fahrten präzise Informationen über die Position von parkenden Fahrzeugen am Straßenrand zu gewinnen und daraus Parkplatzbelegungsstatistiken zu generieren.

Unser Verfahren zur Erfassung besteht im Wesentlichen aus fünf Schritten (Bock et al., 2015):

- Wiederholte Datenaufzeichnung auf einer festgelegten Messroute
- Aufbereitung der Laserscandaten
- Segmentierung der Punktwolken für einzelne Objekte
- Identifikation von parkenden Fahrzeugen aus Objektpunktwolken mittels Klassifikation
- Aggregation der geparkten Fahrzeuge auf dem Straßengraphen.

Die Datenerfassung erfolgte auf einer vorgegebenen Route von über 5 Kilometern durch mehrere Stadtteile von Hannover (siehe Abb. 8 links). Insbesondere deckt die Strecke ein Wohngebiet und das Stadtzentrum ab, um charakteristische Unterschiede im Parkverhalten zu erfassen. Durch insgesamt zehn Aufzeichnungen an einem Tag vom frühen Morgen bis in die Abendstunden konnten auch zeitliche Unterschiede abgedeckt werden.

Zur Aufbereitung der Laserscandaten ist es vor allem notwendig, die große Menge an Daten (mehr als eine halbe Milliarde Punkte pro Messfahrt) geeignet aufzuteilen, sinnvoll zu reduzieren und weitere Attribute für jeden Punkt zu berechnen. Zur räumlichen Trennung werden die Daten in quadratische Kacheln mit einer Kantenlänge von 25 m aufgeteilt. Da manche Gebiete mehrfach während einer Messfahrt von den Scannern erfasst werden, findet auch eine zeitliche Separierung statt. Um lokale Punktanhäufungen (z.B. wegen geringer Fahrtge-

schwindigkeit) zu vermeiden, werden die Daten ausgedünnt und nur jeweils ein Punkt pro Rasterzelle in einem feinen Raster weiterverwendet. Schließlich werden noch weitere Attribute wie beispielsweise die Normalenvektoren berechnet, die für die weiteren Berechnungsschritte notwendig sind.



Abb. 8: Links: Übersicht der Messroute in Hannover. Rechts: Beispiel für das Segmentierungsergebnis eines Straßenabschnittes.

Bei der Segmentierung der einzelnen Kacheln werden die Punktwolken in einzelne Objektpunktwolken aufgeteilt. Hierzu wird zunächst der Boden der Punktwolke geschätzt. Ausgehend von den tiefsten Punkten mit vertikalem Normalenvektor werden über einen Region Growing Ansatz nach und nach benachbarte Punkte hinzugenommen, wenn sie ebenfalls einen vertikalen Normalenvektor besitzen. Alle Bodenpunkte werden anschließend aus jeder Kachel entfernt, so dass Lücken zwischen den Punktwolken der einzelnen Objekte entstehen. Jeweils von einem zufälligen Ausgangspunkt beginnend können nun die einzelnen Objekte über ein erneutes Region Growing separiert werden. Um die Nachbarschaft von Punkten effizient zu berechnen, werden dabei die Punkte in eine Gitterzellendatenstruktur überführt. Ein Beispiel für das finale Segmentierungsergebnis ist in Abb. 8 rechts dargestellt. Während dieses Verfahren in den meisten Fällen erfolgreich ist, schlägt das Verfahren vor allem bei dicht benachbarten Objekten fehl, die nicht mehr voneinander getrennt werden können. Andererseits treten auch Fälle auf, in denen Objekte den Laserstrahl kaum reflektieren (z. B. spezielle Fahrzeuglackierungen), so dass diese Objekte nicht als eine einzelne Punktwolke separiert werden können.

Die resultierenden Punktwolken für die einzelnen Objekte werden anschließend klassifiziert, ob sie ein parkendes Fahrzeug oder ein anderes Objekt darstellen. Hierfür werden für jede einzelne Objektpunktwolke zahlreiche Merkmale berechnet, die zur Unterscheidung der beiden Klassen charakteristisch sind. Dazu gehört zunächst die Geometrie des Objektes mit Länge, Breite und Höhe sowie den Längenverhältnissen. Auch wird betrachtet, welcher Anteil der Punkte zu einer linearen, ebenen, zylindrischen oder streuenden Struktur gehört. Beispielsweise besteht ein Fahrzeug vor allem aus ebenen Anteilen, während ein Busch mit seinen Blättern Normalenvektoren in beliebigen Richtungen besitzt. Darüber hinaus werden Merkmale für die Bewegung der Objekte geschätzt, indem die Punktwolken der beiden Laserscanköpfe miteinander verglichen werden. Dadurch lassen sich parkende von fahrenden Fahrzeugen unterscheiden. Alle Merkmale werden genutzt, um einen Random Forest Klassifikator zu trainieren und zu nutzen. Dieser Klassifikator besitzt die Vorteile, dass er sich leicht interpretieren lässt, geringe Rechenzeiten aufweist und robust gegen Overfitting ist (Breiman, 2001). Bei einer Auswertung auf den aufgezeichneten Daten zeigt sich, dass der Klassifikator etwa 96 % aller parkenden Fahrzeuge erkennt bei weniger als 2 % Falscherkennungen. Hauptgrund für nicht erkannte parkende Fahrzeuge sind unvollständige Punktwolken durch Verdeckungen. Ein Beispiel für ein Klassifikationsergebnis ist in Abb. 9 dargestellt.

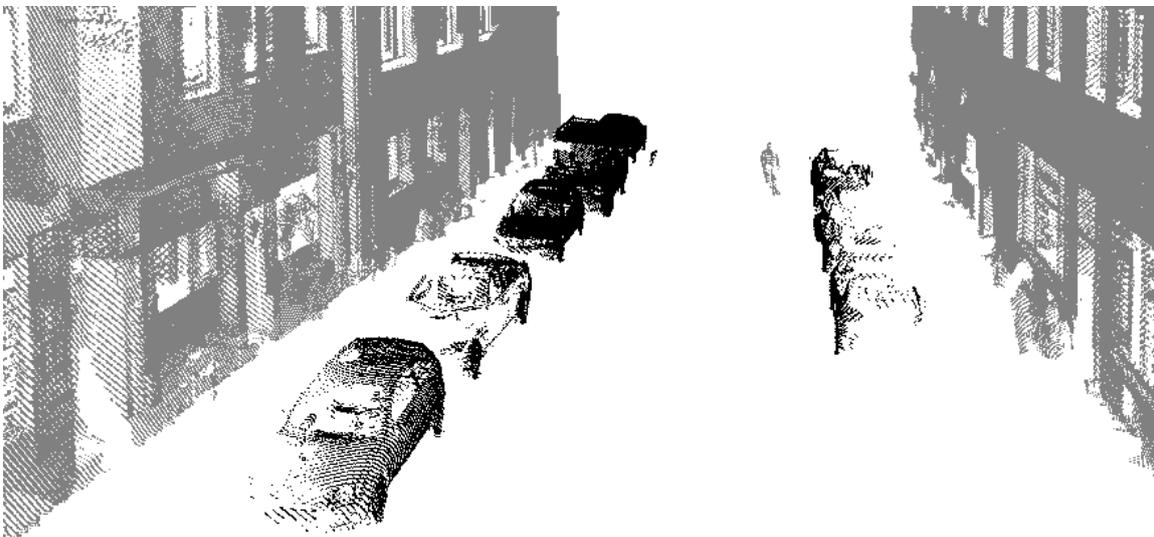


Abb. 9: Beispiel für das Klassifikationsergebnis mit einer Trennung von parkenden Autos (schwarz) von allen anderen Objekten (grau).

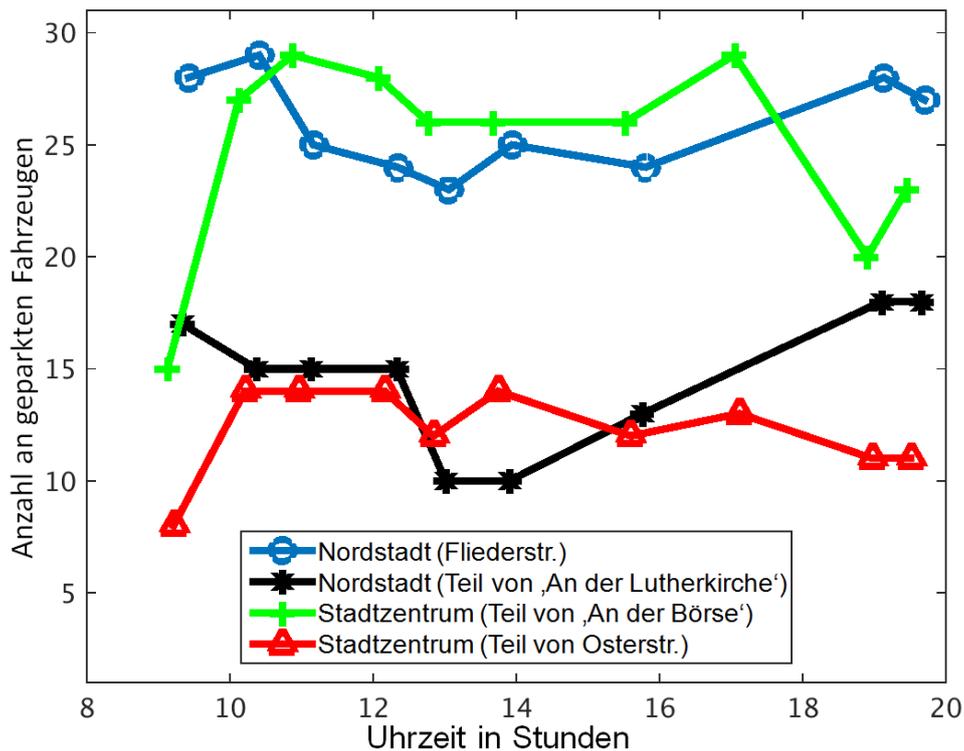


Abb. 10: Beispiel des Tagesverlaufs der Anzahl parkender Fahrzeuge für verschiedene Straßenabschnitte im Stadtzentrum und im Wohngebiet (Nordstadt).

Die Positionen der erkannten parkenden Fahrzeuge werden anschließend auf ein Straßennetzwerk projiziert. Damit sind im Anschluss Auswertungen für einzelne Straßenabschnitte möglich. Ein Beispiel für eine Analyse von Straßenabschnitten über den gesamten Tagesverlauf ist in Abb. 10 dargestellt. Deutlich zu erkennen ist, dass die beiden Straßen aus dem Stadtzentrum die höchste Parkplatznutzung tagsüber zu den Hauptgeschäftszeiten aufweisen, während diese morgens und abends geringer ist. Genau entgegengesetzt verhalten sich die beiden Straßen aus dem Wohngebiet. Hier sind die meisten Fahrzeuge am Morgen und am Abend geparkt, während die Zahl in der Mitte des Tages deutlich abfällt.

4 Dynamische Objekte am Beispiel von Fußgängern und Fahrradfahrern

In diesem Abschnitt wollen wir schließlich auf die Extraktion und Verwendung von Informationen über dynamische Objekte der Szene eingehen. Als dynamische Objekte bezeichnen wir hier Fußgänger und Fahrradfahrer, deren Detektion

insbesondere im Bereich der Fahrerassistenzsysteme von großer Bedeutung ist. Automatisierte Fahrzeuge müssen zunächst in Echtzeit ihre Umgebung erfassen, um nicht nur die eigene Sicherheit, sondern auch die Sicherheit anderer Verkehrsteilnehmer zu gewährleisten. Detektierte dynamische Objekte können neben der direkten Verwendung in automatisierten Fahrzeugen und Fahrerassistenzsystemen auch in einer Karte aggregiert werden. Diese sollte aus den Daten möglichst vieler Messungen erstellt werden und gibt somit die Wahrscheinlichkeit an, mit der dynamische Objekte in bestimmten Regionen auftreten.

Die hieraus resultierenden Anwendungen sind vielfältig. Einerseits kann eine Karte dynamischer Objekte in Zukunft dazu verwendet werden, das Fahrverhalten vollautomatisierter Fahrzeuge je nach Gefahrenpotential in verschiedenen Straßenabschnitten anzupassen. Werden viele Fußgänger und Fahrradfahrer erwartet, die möglicherweise auch häufig die Straße überqueren, so wird die Geschwindigkeit gedrosselt. Geschwindigkeitsbegrenzungen könnten also in Zukunft teilautomatisch durch eine Auswertung der Karte festgelegt werden. Auch für Standortanalysen oder die Nahverkehrsplanung sind die Daten interessant. Wo halten sich besonders viele Menschen auf? Wo lohnt es sich, ein Geschäft zu eröffnen oder eine Haltestelle für den Nahverkehr zu errichten?

Die Verwendung von LiDAR-Sensoren hat gegenüber Kamera- oder Radar-Systemen den Vorteil einer hohen Genauigkeit bei großer Reichweite. Im Falle von 3D-Laserscannern ist auch die Auflösung vergleichsweise hoch, wodurch es möglich ist, für Objekte im Straßenraum Merkmale zu berechnen, die deren Größe und Form beschreiben. Hierfür können neben der Breite und Höhe auch komplexe Merkmale, wie die Elemente der Kovarianzmatrix verwendet werden, die sich aus einer Hauptkomponentenanalyse des Objektes ergibt (Navarro-Serment et al., 2010). Weiter ist es hilfreich, die Information aus dem Intensitätskanal des Laserscanners zu verwenden (Kidono et al., 2011). Diese Merkmale können für jedes Objekt bestimmt werden, um eine Klassifikation in dynamische (Fußgänger, Fahrradfahrer) und andere Objekte durchzuführen. Häufig verwendete Klassifikatoren sind hierbei Support Vector Machines (Schölkopf und Smola, 1998) und Random Forersts (Breiman, 2001).

Durch die stärker werdende Automatisierung von Fahrzeugen nimmt auch die Verbreitung von in Fahrzeugen verbauten LiDAR-Systemen zu. In den Laserscans detektierte Fußgänger und Fahrradfahrer können dann in einer gemeinsamen Datenbank akkumuliert werden, um eine stets aktuelle, hochauflösende Karte dynamischer Objekte zu erstellen. Um diesen Ansatz zu testen, haben wir die Daten unseres LiDAR Mobile Mapping Systems verwendet. Zu zwölf unter-

schiedlichen Zeiten wurden entlang einer etwa fünf Kilometer langen Trajektorie Messungen mit dem System durchgeführt.

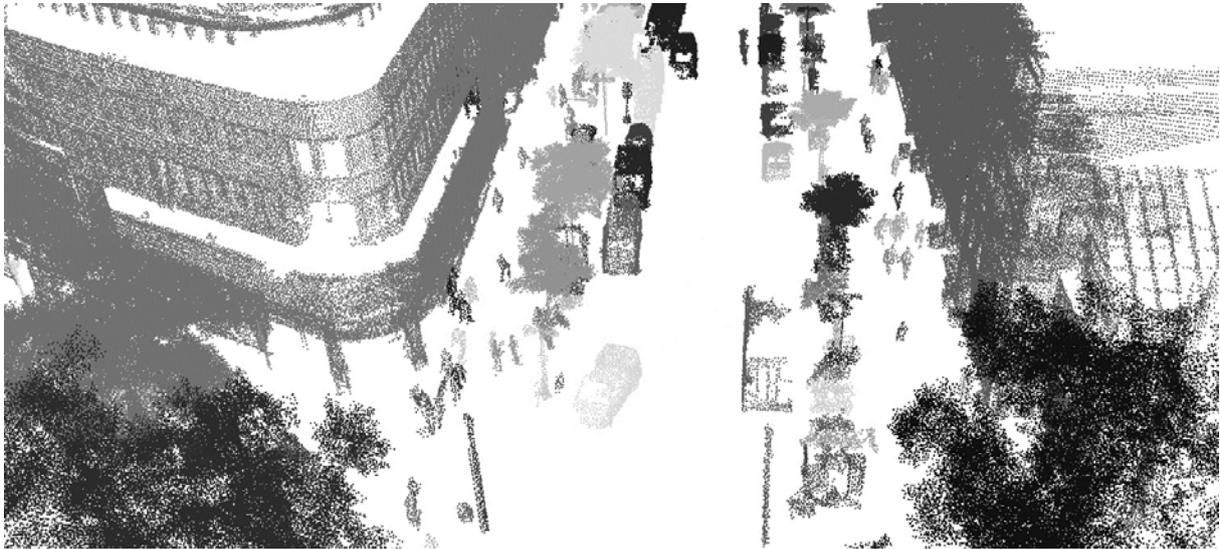


Abb. 11: Segmentierte Objekte eines Ausschnitts der Punktwolke. Der Boden wurde entfernt, Häuserfassaden und Bäume sind noch enthalten.



Abb. 12: Klassifizierte Objekte mit Fußgängern und Fahrradfahrern (schwarz) und anderen Objekten (grau).

In einem ersten Schritt werden die einzelnen Objekte aus der Punktwolke segmentiert. Anschließend folgt die Klassifikation, in der die Objekte anhand von Merkmalen der Klasse *dynamisch* (Fußgänger, Fahrradfahrer) oder *statisch* zugeordnet werden. Ähnlich wie in Abschnitt 3 beschrieben wurde im ersten

Schritt ein Region Growing Algorithmus verwendet, um alle zum Boden gehörigen Punkte von den restlichen Objektpunkten zu trennen und anschließend die übrigen Objekte zu einzelnen Punktclustern zusammenzufügen. Wie in Abb. 11 zu erkennen ist, beinhaltet die Szene weiterhin Häuserfassaden und Bäume, die sich schon auf Grund ihrer Größe leicht als Kandidaten für Fußgänger und Fahrradfahrer ausschließen lassen. Aus diesem Grund wurden die Objekte anhand ihrer Breite und Höhe gefiltert.

Die Klassifikation wurde mit insgesamt 171 Merkmalen durchgeführt, die die Form der Objekte beschreiben, basierend auf dem Ansatz von Kidono et al. (2011). Als Klassifikator wurde ein Random-Forest-Algorithmus aus der OpenCV-Library (Bradski, 2000) verwendet. Es wurden insgesamt 2.200 Objekte mit bereits bekannter Klassifizierung als Trainingsdaten genutzt. Abb. 12 zeigt klassifizierte Fußgänger und Fahrradfahrer (schwarz) in einer typischen Szene im innerstädtischen Bereich. Insgesamt konnten 79 % der dynamischen Objekte detektiert werden, wobei 4 % der Objekte fälschlicherweise als Fußgänger oder Fahrradfahrer klassifiziert wurden. Abb. 13 (links, Mitte) zeigt einen detektierten Fußgänger und einen Fahrradfahrer mit einer jeweils typischen Form. Die Ursache von False-Negatives, also nicht erkannten dynamischen Objekten, war häufig eine fehlerhafte Segmentierung. Fußgänger, die zum Aufnahmezeitpunkt nahe beieinander gingen, konnten beispielsweise nicht voneinander getrennt werden (siehe Abb. 13, rechts).

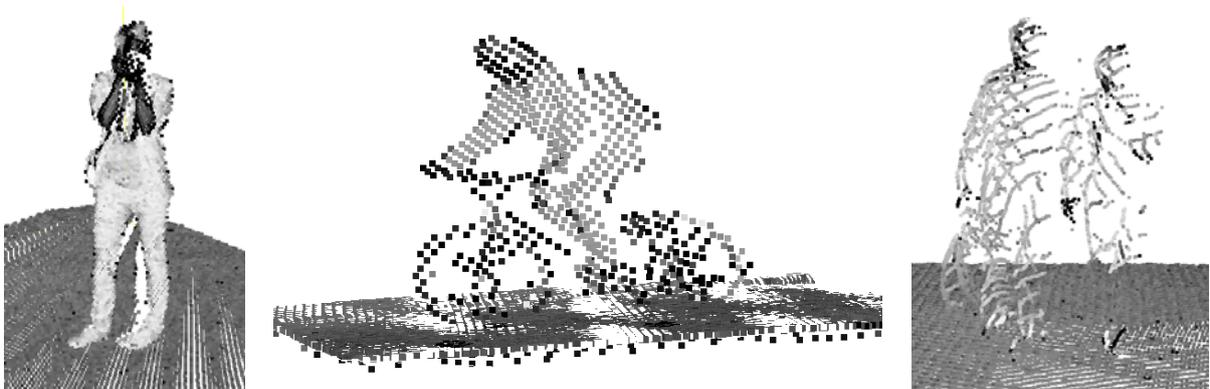


Abb. 13: Beispiele für Punktcluster dynamischer Objekte. Einzelne Fußgänger (links) und Fahrradfahrer (Mitte) konnten in den meisten Fällen detektiert werden. Fußgänger-Paare (rechts) verursachten häufig Fehlklassifikationen.

Aus den Daten wurden insgesamt über 10.000 Fußgänger und Fahrradfahrer vollautomatisch detektiert und anschließend in eine Karte eingetragen, welche als 2D-Raster mit einer Zellenbreite von einem Meter realisiert wurde. Die Position jedes detektierten Fußgängers und Fahrradfahrers wurde verwendet, um den

Wert der jeweiligen Rasterzelle an dieser Stelle und in ihrer Umgebung mit Hilfe eines normalverteilten Kerns zu erhöhen.

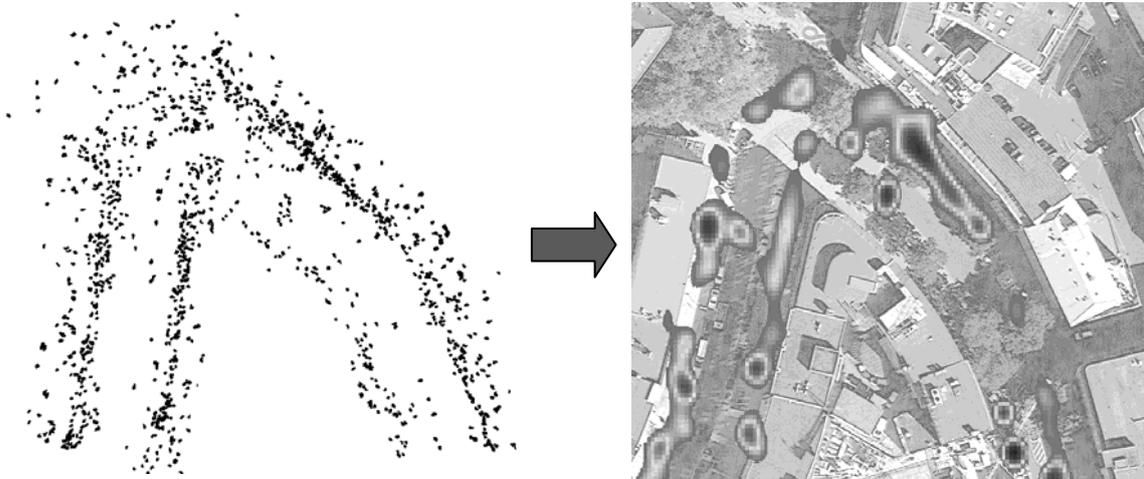


Abb. 14: Ausschnitt der detektierten dynamischen Objekte aller zwölf Messfahrten (links) und der hieraus akkumulierten Karte (rechts).

Für die vorliegende Anwendung wurden Rasterzellen zusätzlich mit dem Abstand zur Fahrbahn gewichtet, da Fußgänger und Fahrradfahrer, die sich in der Nähe oder auf der Fahrbahn befinden, im Straßenverkehr für Fahrzeuge relevanter sind. Dieser Abstand kann aus der Trajektorie des Erfassungsfahrzeugs gewonnen werden. Abb. 14 zeigt einen Ausschnitt der erstellten Karte im Innenstadtbereich von Hannover. Es sind deutlich Hotspots zu erkennen, an denen die Wahrscheinlichkeit für Fußgänger und Fahrradfahrer hoch ist, wohingegen in anderen Regionen kaum dynamische Objekte auftreten.

5 Zusammenfassung und Ausblick

Bereits heute ist es möglich, die Umgebung mittels sehr dicht und sehr präzise messender Systeme zu erfassen. Im Unterschied zu früheren Ansätzen kann dies bei Mobile Mapping Systemen direkt aus dem fahrenden Verkehr heraus erfolgen, so dass große Flächenleistungen erzielbar sind. Die resultierenden Datenmengen erfordern Verfahren, welche automatisiert ablaufen. Im vorliegenden Beitrag haben wir Algorithmen für die Extraktion statischer, mittelfristig veränderlicher und dynamischer Objekte aufgezeigt.

Zum gegenwärtigen Zeitpunkt ist das eingesetzte LiDAR Mobile Mapping System, aufgrund der Kosten für die Beschaffung und den Betrieb, sicherlich noch nicht geeignet, um im großen Umfang für die Erstellung „echtzeitfähiger“ Kar-

ten eingesetzt zu werden. In Zukunft werden jedoch „Crowd Mapping“ Ansätze zum Zuge kommen, welche über die millionenfach in Kraftfahrzeugen verbauten Sensoren ein echtzeitnahes Abbild der Umgebung erzeugen können. Die Herausforderungen liegen dann vornehmlich darin, Algorithmen bereitzustellen, die nicht nur präzise und zuverlässige Ergebnisse liefern, sondern auch ausreichend skalierbar sind.

Literatur

- Anguelov, D., Dulong, C., Filip, D., Früh, Ch., Lafon, S., Lyon, R., Ogale, A., Vincent, L., Weaver, J. (2015): Google Street View: Capturing the World at Street Level, IEEE Computer, vol. 43.
- Bock, F., Eggert, D., Sester, M. (2015): On-Street Parking Statistics using LiDAR Mobile Mapping, Proceedings of the 18th IEEE Conference on Intelligent Transportation Systems.
- Bradski, G. (2000): The OpenCV Library, Dr. Dobb's Journal of Software Tools.
- Breiman, L. (2001): Random Forests. Machine Learning, Volume 45, Kluwer Academic Publishers, S. 5-32.
- Brenner, C. (2009a): Extraction of Features from Mobile Laser Scanning Data for Future Driver Assistance Systems. In: Sester, M.; Bernard, L. & Paelke, V. (Hg.): Proceedings of the 12th AGILE conference. Lecture notes in Geoinformation and Cartography. Berlin: Springer, S. 25–42.
- Brenner, C. (2009b): Global Localization of Vehicles using Local Pole Patterns, Proc. DAGM 2009, 31st annual symposium of the German Association for Pattern Recognition, Springer LNCS 5748, S. 61-70.
- Dold, C., Brenner, C (2004): Automatic Matching of Terrestrial Scan Data as a Basis for the Generation of Detailed 3D City Models, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 35 (Part B3), 1091-1096.
- Felzenszwalb, P. F., Huttenlocher, D. P. (2004): Efficient Graph-Based Image Segmentation, International Journal of Computer Vision, Vol. 59, No. 2.
- Fischler, M. A., Bolles, R. C. (1981): Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography. Communications of the ACM 24(6), 381-395.
- Hauert, J.-H., Brenner, C. (2009): Vehicle Localization by Matching Triangulated Point Patterns, Proc. 17th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems, Seattle, WA, USA, S. 344-351.

- Kidono, K., Miyasaka, T., Watanabe, A., Naito, T., Miura, J. (2011): Pedestrian recognition using high-definition lidar, Proc. Intelligent Vehicles Symposium, IEEE, S. 405-410.
- Klingner, B., Martin, D., Roseborough, J. (2013): Street View Motion-from-Structure-from-Motion, Proceedings of the International Conference on Computer Vision, IEEE.
- Navarro-Serment, L. E., Mertz, C., Hebert, M. (2010): Pedestrian detection and tracking using three-dimensional LADAR data, The International Journal of Robotics Research, Vol. 29, No. 12, S. 1516-1528.
- Riegl (2015): RIEGL Laser Measurement Systems GmbH, VMX-450 Datenblatt, http://www.riegl.com/uploads/tx_pxpriegl/downloads/DataSheet_VMX-450_2015-03-19.pdf. Letzter Zugriff 16.10.2015.
- Schlichting, A., Brenner, C. (2014): Localization using automotive laser scanners and local pattern matching, Proc. Intelligent Vehicles Symposium, IEEE, S. 414-419.
- Schölkopf, B., Smola, A. (1998): Support Vector Machines, Encyclopedia of Biostatistics.
- Wamelen, P.B.V., Li, Z., Iyengar, S. S. (2004): A fast expected time algorithm for the 2-D point pattern matching problem. Pattern Recognition 37(8), S. 1699-1711.