



GRUPPE LASER SCANNING

Rein rechnerisch: Objekte automatisiert erkennen

Was der Mensch in einer belebten Straße wahrnimmt, gleicht einem Wimmelbild: Autos, Schilder, Bäume, Personen und Gebäude, die einander teilweise verdecken. Das Gehirn klassifiziert und lokalisiert all diese Objekte mühelos. Wie komplex dieser Vorgang ist, zeigt sich beim Versuch ihn zu automatisieren. In einem Forschungsprojekt entwickelt Fraunhofer IPM Algorithmen, mit denen sich Straßenbestandsobjekte automatisch erkennen und klassifizieren lassen. Die Basis für die Mustererkennung bilden künstliche neuronale Netze.

Für die Vermessung von Infrastruktur werden heute leistungsfähige Kameras oder Laserscanner eingesetzt, die hochaufgelöste Bilder bzw. sehr präzise, georeferenzierte Messdaten liefern. Moderne Laserscanner nehmen mehrere Millionen Messpunkte pro Sekunde auf, die als 3D-Punktwolke ein detailreiches Abbild der Umgebung ergeben. Die Auswertung geschieht in der Regel manuell durch Sichten von sehr umfangreichen Daten (Punktwolken und Bilddaten). Diesen zeitaufwändigen Prozess zumindest teilweise zu automatisieren, ist das Ziel eines Forschungsprojekts, das Fraunhofer IPM im Auftrag der Lehmann + Partner GmbH für die Bundesanstalt für Straßenwesen (BASt) durchführt. Dabei werden Algorithmen entwickelt, die einzelne Straßeninfrastrukturelemente in 3D-Messdaten automatisiert erkennen, klassifizieren und lokalisieren.

Für die Auswertung von Straßenszenen setzen die Wissenschaftler auf komplexe Lernalgorithmen, die auf dem Konzept des »Deep Learning« mit künstlichen neuronalen Netzen (KNN) basieren und klassischen Methoden der Objekterkennung inzwischen überlegen sind. Letztere nutzen vom Entwickler vorgegebene Merkmalsätze; KNN

hingegen erlernen die relevanten Merkmale anhand von Trainingsdaten. In KNN durchläuft die eingespeiste Information eine Vielzahl miteinander verknüpfter künstlicher Neuronen, wird verarbeitet und an weitere Neuronen weitergegeben. Mithilfe manuell annotierter Trainingsdaten werden für bestimmte Eingangsmuster zugehörige Ausgabemuster erlernt. Auf Basis dieser »Erfahrungswerte« können neuartige Eingangsdaten dann in Echtzeit analysiert werden. Dabei erweisen sich KNN als sehr robust gegenüber Variationen von charakteristischen Farben, Kanten oder Formen.

Datenfusion: Scannerdaten plus Kamerabilder bilden Datenbasis

Je detaillierter die Informationen im Datensatz, desto besser gelingen Objekterkennung und -klassifizierung. Grundlage im Projekt sind Kamera- und Scandaten, die mit einem Messfahrzeug des Projektpartners Lehmann + Partner aufgenommen wurden, das mit von Fraunhofer IPM entwickelten Laserscannern ausgerüstet ist. Fusionierte Scanner- und Kameradaten erweisen sich als geeignete Ausgangsbasis für die automatisierte Objekterkennung. Ein Ansatz sieht vor,

DEEP LEARNING ist als Methode des »Machine Learning« ein Teilbereich der künstlichen Intelligenz, die auf lernende Algorithmen setzt. Das Erkennen von Objekten in einem Bild beispielsweise erfolgt anhand von Trainingsdatensätzen. »Deep Learning« basiert auf künstlichen neuronalen Netzen und erweist sich im Vergleich zu klassischen Methoden der Objekterkennung als robuster gegenüber variierenden Formen, Verdeckungen, Beschädigungen oder Ausbleichungen, wie sie in Straßenszenen typisch sind.

die georeferenzierten Punkte der Scannerdaten zunächst in ein Rasterformat zu überführen, das Tiefeninformationen enthält, und dann mit den RGB-Kameradaten zu verknüpfen. Dieser pixelbasierte RGB-D(ept)-Datensatz enthält zu jedem RGB-Kamerabild ein entsprechendes Tiefenbild und bildet ein ideales Eingabeformat für KNN. Die Wissenschaftler gehen davon aus, dass die Tiefenwerte die Separierung sich überlagernder Objekte unterstützen und für eine insgesamt noch robustere Klassifikation und Lokalisierung sorgen können.

Georeferenzierte Objekte in 3D durch semantische Segmentierung

Die Architektur des Netzes, also die Anzahl der Netzschichten und die Art der hierarchischen Verknüpfungen, ist an die jeweilige Aufgabe angepasst. Für das Trainieren des Netzes wird ein Trainingsdatensatz erstellt. Dazu erfolgt zunächst eine manuelle semantische Segmentierung der Bilder, bei der jedes Pixel einer bestimmten Objektklasse zugeordnet wird. Ein mit diesen Daten trainiertes Netz kann mithilfe eines neuen Trainingsdatensatzes jederzeit um weitere Objektklassen erweitert werden. Anhand der Pixelkoordinaten der in den Bilddaten erkannten Objekte lässt sich die Segmentierung in die Punktwolke zurückprojizieren. Dazu müssen Kamera und Laserscanner exakt zueinander ausgerichtet sein und die entsprechenden Kalibrationsparameter einmalig in einem entsprechenden Prozess bestimmt werden. Mit der Segmentierung der Punktwolke lassen sich dann georeferenzierte Objekte in 3D identifizieren.

Das Thema automatisierte Objekterkennung ist überall dort von Interesse, wo große Datenmengen ausgewertet werden müssen. Noch höhere Anforderungen als die Bestandserfassung von Infrastruktur stellt in Zukunft die Automobilindustrie, die für das autonome Fahren ebenfalls auf die Technologie setzt. Hier müssen bewegte Objekte in Echtzeit erkannt werden – noch sind dabei die natürlichen neuronalen Netze des menschlichen Gehirns überlegen.



1 Straßenobjekte in Messdaten erkennen, klassifizieren und lokalisieren ist aufwändig. Mustererkennung auf Basis künstlicher neuronaler Netze automatisiert den Prozess.

2 Kamerabild und ausgewertetes Messbild: Farbige Segmentierungsmasken markieren die Form der erkannten Objekte.