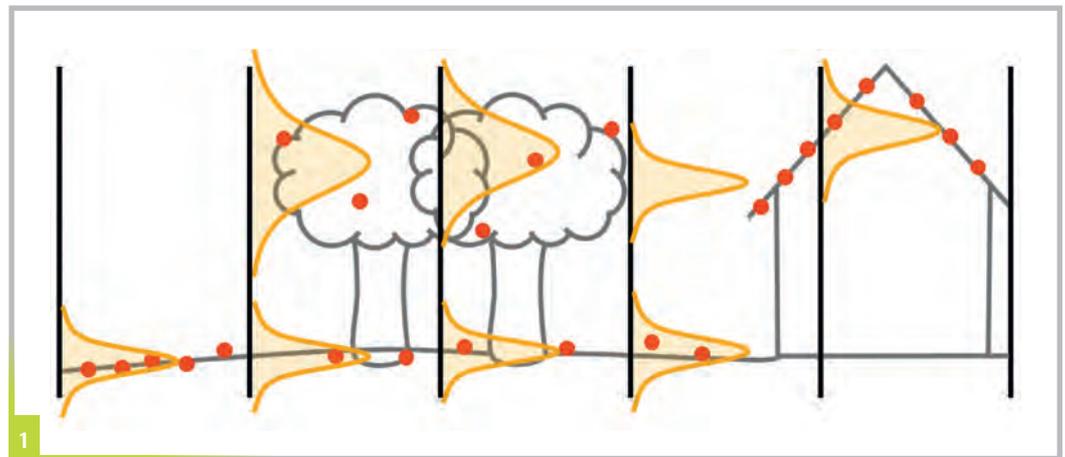


Zur automatischen Klassifikation von 3D-Punktwolken

Landvermessung mittels Laserscanning und digitaler Bildanalyse

Die Landesvermessung hat zum Ziel, ein sehr genaues Geländemodell von Landesflächen zu erstellen, da diese zum Beispiel für den Hochwasserschutz, die Trassenplanung oder ähnliches wichtig sind.

Am Institut für Kartographie und Geoinformatik werden in einem Projekt zusammen mit dem FZ:GEO-Partner LGLN (Landesvermessung und Geobasisdaten Niedersachsen) sowie den Landesvermessungen in Schleswig-Holstein und Mecklenburg-Vorpommern KI-Methoden und im Speziellen Deep Learning eingesetzt, um aus großen Datenmengen automatisiert und dennoch präzise Geländemodelle erstellen zu können.



Eine der Aufgaben der Landesvermessung ist es, ein hochgenaues Geländemodell der Landesfläche bereitzustellen und aktuell zu halten. Dies ist für viele Aufgaben relevant, unter anderem für Hochwasserschutz, Trassenplanungen oder Funknetzplanungen. Dafür lässt die Landesvermessung in regelmäßigen Abständen die Landesfläche befliegen und so die Topographie, also die Objekte der Erdoberfläche, aufnehmen. Dies kann in jüngerer Zeit mit zwei unterschiedlichen Technologien erfolgen: mittels Laserscanning oder mittels digitaler Bildanalyse. Die Landesvermessungen wenden beide Verfahren teilweise alternierend an. Beide Verfahren liefern hochgenaue 3D-Punktwolken, die im Wesentlichen ein sogenanntes Oberflächenmodell darstellen. Diese Punktwolken beinhalten alle Punkte, an denen der Laser-

strahl reflektiert wurde beziehungsweise die von zwei Kamerabildern gesehen wurden. Allerdings enthalten diese Punkte nur die reine Geometrie und gegebenenfalls sensorspezifische Eigenschaften. Sie enthalten jedoch noch keine Semantik, die Rückschlüsse darüber geben kann, ob nun der Boden, ein Baum, ein Dach oder ein Auto aufgenommen wurde. Um ein Geländemodell zu bestimmen, müssen also zunächst die Punkte identifiziert werden, die tatsächlich Bodenpunkte darstellen. Das bedeutet, um ein Geländemodell zu erhalten, muss das gemessene Oberflächenmodell um die Objekte bereinigt werden, die sich – wie zum Beispiel Gebäude oder Vegetation – auf dem Gelände befinden.

In einem Projekt zusammen mit dem FZ:GEO-Partner LGLN (Landesvermessung

und Geobasisdaten Niedersachsen) sowie den Landesvermessungen in Schleswig-Holstein und Mecklenburg-Vorpommern werden KI-Methoden und im Speziellen Deep Learning eingesetzt, um die Punkte in verschiedene, semantische Klassen einzuteilen.

Deep Learning für die Klassifikation von Punktwolken

Deep Learning Methoden, als Teil des Maschinellen Lernens, haben für komplexe Klassifikationsaufgaben in jüngerer Zeit einen enormen Aufschwung erlebt. Dies liegt unter anderem an den verfügbaren, äußerst leistungsfähigen Algorithmen und Entwicklungsumgebungen, an effizienter Hardware, aber auch an der Verfügbarkeit von sehr vielen, großen Datensätzen. Bei dem hier verwendeten Lernverfahren handelt es

sich um eine sogenannte überwachte Klassifikation. Bei dieser werden den Algorithmen Beispiele mit Referenzklassen in Form eines Trainingssets übergeben, anhand derer der Algorithmus „Regeln“ ableitet, um diese im Anschluss auf unbekannte Beispiele anwenden zu können. Eine elementare Voraussetzung für die überwachte Klassifikation ist das Vorhandensein umfangreicher, klassifizierter Beispieldaten, deren Beschaffung aber oft ein manueller und sehr zeitaufwendiger Prozess ist.

Unter dem Begriff „Deep Learning“ sammeln sich eine Vielzahl an verschiedenen Applikationen, die unterschiedlich komplexe Netzwerkstrukturen benötigen. Diese Netzwerkstrukturen sind in Grunde aneinander gekettete, lineare und nicht-lineare Funktionen. In mehreren Disziplinen der Bildanalyse und Fernerkundung haben sich Convolutional Neural Networks (CNNs) als State-of-the-Art-Methode etabliert. Sie arbeiten mit Filtermasken, die die regelmäßige Gitterstruktur von Bilddaten ausnutzen. Durch das Training eines Netzwerkes werden die verschiedenen Parameter der linearen- und nicht-linearen Funktionen bestimmt, die den Zusammenhang zwischen Eingangsdaten und zu bestimmender Klasse identifizieren.

Anders als Bilder weisen 3D-Punktwolken diese regelmäßige Gitterstruktur nicht auf. Für die Klassifikation von Punktwolken mittels CNNs werden in der Wissenschaft daher drei verschiedene Ansätze genutzt: punktweise, voxelweise oder rasterweise Klassifizierung. Bei der punktweisen Klassifizierung werden benachbarte Punkte als eine Einheit oder in Form eines Nachbarschaftsgraphen gemeinsam klassifiziert, wobei hier die Geometrie als auch die Eigenschaften der

einzelnen Punkte verwendet werden. Bei der Klassifikation mittels Voxeln werden die Punkte in räumliche 3D-Würfel geteilt, die ein regelmäßiges Gitternetz darstellen. Neben der Information, ob sich Punkte in dem Würfel befinden oder nicht, kann ein Voxel auch die statistischen Eigenschaften der Punkte als Information enthalten. Der dritte Ansatz der Punktwolkenklassifizierung mit CNNs sortiert die Punkte unabhängig von ihrer Höhe in regelmäßige 2D-Rasterzellen, die anschließend wie ein Bild behandelt werden können. Anders als Grauwerte bei einem Bild werden die Zellen über verschiedene Statistiken der Höhenverteilung wie zum Beispiel die minimale und maximale Höhe oder über punktwolkenspezifische Attribute repräsentiert. Sowohl bei den Voxeln als auch bei den Rastern werden anschließend die Ergebnisse wieder auf die Punkte übertragen.

Ansatz zur Klassifikation von 3D-Punktwolken

Im Projekt mit der Landesvermessung wird unter Berücksichtigung der potenziellen Abdeckungsfläche und der zum Teil sehr unterschiedlichen Punktdichte der Punktwolken eine Eingabestruktur in Form eines 2D-Rasters verwendet. Dazu wird die Punktwolke in Rasterzellen mit einer Kantenlänge von einem Meter zerlegt. Statt mit absoluten Höhen zu arbeiten, die prinzipiell eine Spanne zwischen 0 Meter (Meereshöhe) und 8.849 Metern (Mount Everest) annehmen können, werden stattdessen relative Höhen verwendet, sodass Bodenpunkte unabhängig vom Gelände eine Höhe nahe 0 aufweisen. In jeder Zelle wird anschließend die Punktverteilung analysiert und mittels Bayes-Informationskriterium geprüft, ob die Höhenverteilung der Punkte eher einer

oder zwei disjunkter Verteilungen ähnelt. Diese Verteilungen werden anschließend in Form von Normalverteilungen mittels ihres empirischen Mittelwertes \bar{x} und ihrer Standardabweichung s approximiert. Die Verteilungen von Objekten abhängig von ihrer Klasse können dabei sehr unterschiedlich ausfallen wie in *Abbildung 1* dargestellt. Bei einer Rasterzelle, die nur Bodenpunkte enthält, wird die Verteilung über einen relativ kleinen Mittelwert und einer schmalen Standardabweichung charakterisiert. Bei einer Rasterzelle, die sowohl einen Baum als auch Boden enthält, wird eine Verteilung idealerweise die Bodenpunkte abdecken, während die andere mit einer deutlich größeren Standardabweichung und einem höheren Mittelwert den Baum beschreibt. Schließlich haben Gebäude einen ähnlich hohen Mittelwert, aber eine deutlich kleinere Standardabweichung als Bäume. Folglich können diese Objekte rein geometrisch getrennt werden.

Beispiel

Die Evaluation der Methode erfolgt anhand zweier Laser-scanning-Datensätze in Rostock und Braunschweig. Neben der generellen Klassifikationsgenauigkeit wurden auch die Transfereigenschaften des Netzwerkes auf ein anderes räumliches Gebiet untersucht, da ein ideales Netz auch in der Lage sein muss, zu generalisieren. Die Qualität der Ergebnisse wird als sogenanntes mean F1-Score angegeben, wobei ein ideales Ergebnis einem Wert von 100 Prozent entspricht. Das Netzwerk lernt mittels Trainingsdaten aus Rostock, Punktwolken zu klassifizieren. Anschließend wird das gelernte Modell genutzt, die Klassen für die Testdaten aus Rostock und Braunschweig zu präzisieren.

Abbildung 1
Schematische Visualisierung des vorgeschlagenen Algorithmus, der Höhenverteilungen als Eingabegrößen für die Klassifizierung verwendet. Grau: zugrundeliegende Objekte, schwarz: Rastergitter, rot: gemessene Punkte in der Punktwolke, gelb: berechnete Höhenverteilungen für jede Zelle.
Quelle: Politz et al., 2020

Testgebiete	Gelände	Gebäude	Wasser	Brücke	Nicht-Gelände	Gesamtgenauigkeit
Rostock	96.3	91.3	92.3	86.3	83.0	93.4
Braunschweig	94.1	95.4	--	38.7	88.9	92.7

Tabelle
 Klassifikationsgenauigkeit ausgedrückt als F1-Score in Prozent für die beiden Testgebiete.
 Quelle: Politz et al., 2020

In der *Tabelle* sind die Klassifikationsgenauigkeiten für Rostock und Braunschweig zu sehen.

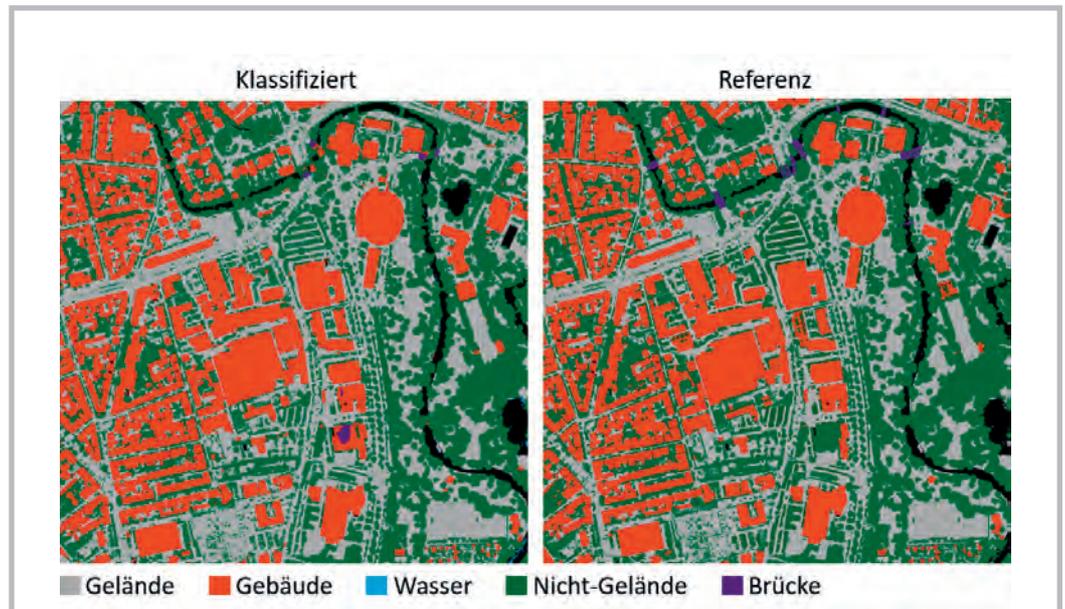
Die Gesamtgenauigkeit über alle Objektklassen ist mit über 92 Prozent sehr hoch. Da die Testdaten aus Rostock natürlich eine größere Ähnlichkeit bezüglich der Raumstruktur und Verteilung von Objekten aufweisen als die Innenstadt in Braunschweig, verwundert es nicht, dass die Gesamtgenauigkeit in Rostock mit 93.4 Prozent etwas höher liegt als in Braunschweig mit 92.7 Prozent. Geländepunkte lassen sich dabei am besten bestimmen, die Klasse der Nicht-Geländepunkte am schlechtesten – hierunter fallen allerdings auch verschiedene Objekte wie jegliche Art von Vegetati-

on, Freileitungen oder Autos. Diese Nicht-Geländepunkte sind in Braunschweig deutlich besser klassifiziert worden als in Rostock. Dies liegt vor allem an der begrenzten Überlagerung von Gebäuden mit Vegetation, wodurch die strikte Trennung dieser beiden Klassen in Braunschweig deutlich vereinfacht wird. Brücken wurden in Braunschweig deutlich schlechter klassifiziert als in Rostock, was daran liegt, dass der Trainingsdatensatz in Rostock nur eine sehr geringe Menge an Beispieldaten für diese Klasse besitzt. Während Braunschweig von innenstädtischen, breiten Kfz-Brücken geprägt ist, sind die Brücken in der Umgebung von Rostock deutlich kleiner, schmaler und vorwiegend außer-

halb des städtischen Gebietes an Landstraßen und Autobahnen zu finden. Am Beispiel der Brücken zeigt sich daher ein Defizit im Trainingsdatensatz.

Abbildung 2 zeigt die Ergebnisse qualitativ. Visuell lassen sich kaum Unterschiede wahrnehmen. An manchen Gebäuden sind die Dachränder teilweise unscharf klassifiziert, an anderer Stelle tauchen fehlerhafte Klassifikationen durch Gebäude oder Brücken auf. Generell bestätigt aber der visuelle Eindruck die hohe Klassifikationsgüte.

Ähnlich gute Ergebnisse wurden auch in Testdatensätzen in anderen Regionen Deutschlands sowie in den Niederlanden erzielt. Ebenso konnte das Netzwerk erfolgreich mit Punktwolken aus Rostock, die ursprünglich aus Bildern generiert wurden, trainiert und getestet werden und erzielte eine Gesamtgenauigkeit von 97.6 Prozent.



Vom Netzwerk klassifizierte Testdaten in Braunschweig und deren Referenzklassen. Objekte aus der Gelände-, Gebäude- oder Nicht-Gelände-Klasse sind nahezu identisch zwischen der Klassifizierung und der Referenz, was sich in hohen mean F1-Scores widerspiegelt. Lediglich die Klasse Brücke verursacht größere Probleme. Beispiele davon sind nahe des Flusses sichtbar, wo statt der Klasse Brücke die Klasse Nicht-Gelände prädiiziert wird, sowie im Süden der Kachel, wo statt eines Gebäudes fälschlicherweise eine Brücke klassifiziert wird.
 Quelle: Politz et al., 2020

Fazit

Der Einsatz von Maschinellen Lernverfahren verspricht in vielen Fachgebieten ausgezeichnete Ergebnisse, die die bisherigen Methoden deutlich übertreffen. Herausforderungen beim Einsatz dieser Verfahren liegen im Design der Architektur der Netze und in der geeigneten Auswahl und Aufbereitung der Eingangsgrößen. Im vorliegenden Fall wurde die Geometrie der Punktwolken derart approximiert, dass ein einmal angelerntes Netzwerk ohne großen Qualitätsverlust und weiteres Training auf andere Gebiete und andere Punktwolkentypen angewendet werden kann.

Literatur

Politz, F., Sester, M., and Brenner, C.:
 GEOMETRY-BASED POINT CLOUD
 CLASSIFICATION USING HEIGHT DIS-
 TRIBUTIONS, ISPRS Ann. Photogramm.
 Remote Sens. Spatial Inf. Sci., V-2-
 2020, 259–266, <https://doi.org/10.5194/isprs-annals-V-2-2020-259-2020>, 2020.



Prof. Dr.-Ing. habil. Monika Sester

Jahrgang 1961, ist Professorin und Leiterin des Instituts für Kartographie und Geoinformatik. In der Forschung beschäftigt sie sich mit ihrem Team mit Fragen zur Automation in der räumlichen Datenverarbeitung, etwa die Dateninterpretation, die Ableitung von Karten unterschiedlicher Maßstäbe oder die Visualisierung. Sie ist Ko-Sprecherin des FZ:GEO.

Kontakt: monika.sester@ikg.uni-hannover.de



M.Sc. Florian Politz

Geboren 1991, ist wissenschaftlicher Mitarbeiter im Institut für Kartographie und Geoinformatik. In der Forschung beschäftigt er sich mit der Klassifikation und Änderungsdetektion von luftgestützten Punktwolken mittels künstlicher Intelligenz. Dabei liegt der besondere Fokus seiner Arbeit auf der Integration verschiedener Punktwolkentypen aus Laserscanning und digitaler Bildanalyse. Kontakt:

florian.politz@ikg.uni-hannover.de